



Technische  
Universität  
Braunschweig

Institut für Werkzeugmaschinen  
und Fertigungstechnik



# Qualitätssicherungssystem für die Anlaufphase und den Serienbetrieb einer Batteriezellenproduktion

Thomas Kornas

Schriftenreihe des Instituts für Werkzeugmaschinen und  
Fertigungstechnik der Technischen Universität Braunschweig



**Vulkan Verlag**





# **Qualitätssicherungssystem für die Anlaufphase und den Serienbetrieb einer Batteriezellenproduktion**

Von der Fakultät für Maschinenbau  
der Technischen Universität Carolo-Wilhelmina zu Braunschweig

zur Erlangung der Würde

eines Doktor-Ingenieurs (Dr.-Ing.)

genehmigte Dissertation

von: M. Sc. Thomas Kornas  
geboren in (Geburtsort): Recklinghausen

eingereicht am: 19.01.2021  
mündliche Prüfung am: 29.03.2021

Vorsitz: Prof. Dr.-Ing. Arno Kwade  
Gutachter: Prof. Dr.-Ing. Christoph Herrmann  
Prof. Dr. Thomas Spengler



Bibliografische Informationen der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über [www.dnb.de](http://www.dnb.de) abrufbar.

Zugl. Braunschweig, Techn. Univ., Diss., 2021

ISBN 978-3-8027-8363-0

Das Werk ist urheberrechtlich geschützt, die dadurch begründeten Rechte, insbesondere der Übersetzung, des Nachdrucks, der Entnahme von Abbildungen, der Funksendung, der Wiedergabe auf fotomechanischem oder ähnlichem Wege und der Speicherung in Datenverarbeitungsanlagen bleiben, auch bei nur auszugsweiser Entnahme, vorbehalten.

©Vulkan-Verlag, Essen, 2021

Printed in Germany

Die Wiedergabe von Gebrauchsnamen, Handelsnamen und Warenbezeichnungen usw. in diesem Werk berechtigt auch ohne besondere Kennzeichnung nicht zu der Annahme, dass solche Namen im Sinne der Waren- und Markenschutzgesetzgebung als frei zu betrachten wären und daher von jedermann benutzt werden dürfen.



## Danksagung

Die vorliegende Arbeit entstand während meiner Tätigkeit als Doktorand im Kompetenzzentrum für Batteriezellen der BMW AG von 2017 bis 2020. Während dieser Zeit wurde ich am Institut für Werkzeugmaschinen und Fertigungstechnik (IWF) in der Abteilung Nachhaltige Produktion und Life Cycle Engineering der Technischen Universität Braunschweig betreut.

Mein besonderer Dank gilt meinem Doktorvater, Prof. Dr.-Ing. Christoph Herrmann, für die mir gebotene Möglichkeit zur Promotion, die wertvollen Gespräche und hervorragende fachliche Unterstützung. Zudem möchte ich Prof. Dr. Thomas Spengler, Leiter des Instituts für Automobilwirtschaft und industrielle Produktion der Technischen Universität Braunschweig, für die Übernahme des Korreferats danken. Prof. Dr.-Ing. Arno Kwade, Leiter des Instituts für Partikeltechnik der Technischen Universität Braunschweig, danke ich für die Übernahme des Vorsitzes der Prüfungskommission. Ebenfalls meinen Dank aussprechen möchte ich Prof. Dr.-Ing. Sebastian Thiede, der mich während seiner Zeit am IWF der Technischen Universität Braunschweig wissenschaftlich begleitet und in meinen Veröffentlichungen sowie bei der Durchsicht meiner Arbeit unterstützt hat.

Im Weiteren möchte ich mich bei meinen Kollegen am IWF für die freundliche Aufnahme sowie die gute Zusammenarbeit und Unterstützung bedanken. Mein Dank gilt auch meinem Betreuer und Gruppenleiter Dr.-Ing. Rüdiger Daub, der mich während meiner Zeit bei der BMW AG nicht nur fachlich unterstützt, sondern mir auch den notwendigen Freiraum gewährt hat. Dank gebührt auch allen Studierenden, die mich im Rahmen ihrer Studienarbeiten und Praktika bei der Ausarbeitung und Umsetzung unterstützt haben. Hervorheben möchte ich die Unterstützung durch Michael Kirchhof, Edgar Knack, Klaus Haas sowie durch die Mitglieder der *R Force One*. Ich wünsche allen für die weitere berufliche und wissenschaftliche Karriere alles Gute.

Mein persönlicher Dank geht an meine Frau, Klaudia Kornas, für ihre positive Art, Motivation und uneingeschränkte Unterstützung. Nicht zuletzt gebührt mein Dank meinen Eltern, Katharina und Darius Kornas, die mich während meines bisherigen Lebensweges immer unterstützt und so diese Promotion ermöglicht haben. Ohne die Unterstützung und Liebe meiner Familie wäre ich heute nicht da, wo ich bin. Ihnen ist diese Arbeit gewidmet.



## Inhaltsverzeichnis

Danksagung.....	I
Inhaltsverzeichnis .....	II
Abbildungsverzeichnis .....	V
Tabellenverzeichnis .....	XI
Abkürzungsverzeichnis .....	XII
Formelverzeichnis.....	XIII
<b>1 Einleitung.....</b>	<b>1</b>
1.1 Motivation .....	1
1.2 Zielsetzung und Vorgehensweise .....	4
<b>2 Batteriezellenproduktion und Qualitätsmanagement .....</b>	<b>7</b>
2.1 Batteriezellenproduktion .....	7
2.1.1 Aufbau und Funktionsweise von Lithium-Ionen-Batteriezellen .....	7
2.1.2 Prozesskette zur Herstellung von Lithium-Ionen-Batteriezellen .....	9
2.2 Qualitätsmanagement in Prozessketten .....	12
2.2.1 Prozessketten .....	13
2.2.2 Produktionsanlauf von Prozessketten.....	14
2.2.3 Komplexität in Prozessketten .....	16
2.2.4 Kausalitäten in Prozessketten .....	18
2.2.5 Methoden des Qualitätsmanagements .....	19
2.2.6 Fehlmöglichkeits- und -einflussanalyse (FMEA) .....	24
2.2.7 Qualitätskennzahlen .....	25
2.2.8 Prozessfähigkeitsuntersuchungen .....	26
2.2.9 Datenanalyse .....	29
2.2.10 Bayes-Theorem und Bayessche Netzwerke .....	33
<b>3 Stand der Forschung .....</b>	<b>37</b>
3.1 Bewertungskriterien .....	37

3.2	Diskussion bestehender Ansätze in der Forschung .....	41
3.2.1	Expertenbasierte Ansätze .....	42
3.2.2	Datenbasierte Ansätze .....	46
3.2.3	Ansätze auf Basis Bayesscher Statistik .....	49
3.3	Zusammenfassung der Ansätze in der Forschung .....	52
3.4	Ableitung des Forschungsbedarfes .....	55
<b>4</b>	<b>Konzept eines Qualitätsmanagementsystems für die Produktion von Batteriezellen .....</b>	<b>57</b>
4.1	Ziele und Anforderungen .....	57
4.2	Konzeptentwicklung .....	62
4.3	KPI-System .....	66
4.3.1	Selektion von Kennzahlen für die Qualitätsprüfung einer Prototypen- und Pilotlinienproduktion .....	68
4.3.2	Selektion von Kennzahlen für die Qualitätsprüfung einer Serienproduktion .....	71
4.3.3	Verknüpfung der Kennzahlen zu einem KPI-System .....	74
4.3.4	Zusammenfassung und kritische Gegenüberstellung der Anforderungen .....	76
4.4	FMEA-basiertes Bayessches Netzwerk .....	76
4.4.1	Aufbau Bayesscher Netzwerke .....	79
4.4.2	Simplifizierung der Expertenbefragung .....	82
4.4.3	Durchführung von Inferenzen .....	85
4.4.4	Reduzierung der Berechnungszeit .....	86
4.4.5	Identifikation und Korrektur von Inkonsistenzen .....	88
4.4.6	Quantifizierung von unbekannten Fehlerursachen .....	95
4.4.7	Zusammenfassung und kritische Gegenüberstellung der Anforderungen .....	96
4.5	Self-Service Data Analytics .....	98
4.5.1	Expertengestütztes Konzept zur Datenanalyse .....	100
4.5.2	Synergetische Verknüpfung von experten- und datenbasierten Methoden .....	110

4.5.3	Zusammenfassung und kritische Gegenüberstellung der Anforderungen .....	112
4.6	Implementierung .....	113
4.6.1	Datenebene .....	115
4.6.2	Logik- und Visualisierungsebene .....	120
4.6.3	Zusammenfassung und kritische Gegenüberstellung der Anforderungen .....	130
<b>5</b>	<b>Exemplarische Anwendung .....</b>	<b>132</b>
5.1	Vorstellung des betrachteten Prozesskettenabschnittes .....	132
5.2	Qualitätsprüfung .....	133
5.3	Aufbau des Bayesschen Netzwerkes .....	134
5.4	Fehler-Ursachen-Analyse .....	138
5.5	Datenanalyse .....	140
<b>6</b>	<b>Zusammenfassung und Ausblick .....</b>	<b>144</b>
6.1	Zusammenfassung .....	144
6.2	Kritische Würdigung .....	146
6.3	Ausblick .....	147
<b>7</b>	<b>Literaturverzeichnis .....</b>	<b>151</b>
<b>8</b>	<b>Anhang .....</b>	<b>176</b>
8.1	Kennzahlen .....	176
8.2	Beispielrechnung einer Fehler-Ursachen-Analyse .....	177
8.3	Deskriptive Statistik .....	180

## Abbildungsverzeichnis

Abbildung 1: Anzahl elektrifizierter Fahrzeuge weltweit als Summe aus batterieelektrischen und Plug-In-hybriden Personenkraftwagen, Bussen und Lastkraftwagen (ZSW 2020; INTERNATIONAL ENERGY AGENCY 2019A; INTERNATIONAL ENERGY AGENCY 2019B.).	1
Abbildung 2: Exemplarische Darstellung einer komplexen Prozesskette.	4
Abbildung 3: Grundlegender Aufbau einer Lithium-Ionen-Batteriezele (nach SCHÖNEMANN 2017, S. 12).	8
Abbildung 4: Etablierte Bauformen von Lithium-Ionen-Batteriezele (in Anlehnung an WÖHRLE 2013, S. 112 und PETTINGER 2013, S. 227).	9
Abbildung 5: Prozesskettenstruktur prismatischer Lithium-Ionen-Batteriezele.	10
Abbildung 6: Untergeordnete Themenfelder des Qualitätsmanagements. (DIN EN ISO 9000, S. 14)	12
Abbildung 7: Darstellung der Kategorien von Prozesskettenelementen (in Anlehnung an WESTERMEIER 2016, S. 9).	14
Abbildung 8: Produktionsanlauf und Serienproduktion einer Batteriezelefertigung (in Anlehnung an DYCKHOFF ET AL. 2012, S. 1430).	15
Abbildung 9: Ausprägungsformen von Ursachen-Wirkzusammenhängen (aus WESTERMEIER 2016, S. 14).	17
Abbildung 10: Abgrenzung von komplizierten und komplexen Systemen (ULRICH & PROBST 1995).	18
Abbildung 11: Exemplarischer Datensatz nach ANSCOMBE 1981, S. 17, um die Bedeutung einer Visualisierung herauszustellen.	19
Abbildung 12: Einsatz von Qualitätsmanagementmethoden, zugeordnet anhand der Phasen eines Produktentstehungsprozesses (aus BRÜGGEMANN & BREMER 2015, S. 13).	20
Abbildung 13: Beispiel für einen Fehlerbaum (in Anlehnung an BRÜGGEMANN & BREMER 2015, S. 41).	21
Abbildung 14: Vollständig faktorieller Versuchsplan für vier Eingangsgrößen (aus KLEPPMANN 2011, S. 108).	22

Abbildung 15: Aufbau einer Qualitätsregelkarte (BRÜGGEMANN & BREMER 2015, S. 116). ...	23
Abbildung 16: FMEA-Formblatt nach VDA Band 4. ....	25
Abbildung 17: a) diskretes Qualitätsverständnis zur Berechnung der Prozessfähigkeitsindizes CP bzw. Cpk; b) kontinuierliches Qualitätsverständnis zur Berechnung der Prozessfähigkeitsindizes CPm bzw. Cpmk (nach LINß 2013, S. 447). ....	27
Abbildung 18: Flussdiagramm zur Bestimmung eines anwendungsgerechten Prozessfähigkeitsindizes. ....	29
Abbildung 19: Schritte des Data-Mining-Prozessmodells nach FAYYAD ET AL. 1996, S. 41. ...	30
Abbildung 20: Schritte des Data-Mining-Prozessmodells CRISP-DM (SHEARER 2000). ....	31
Abbildung 21: Zuordnung von Data-Mining-Zielen und Data-Mining-Methoden (ALPAR & NIEDEREICHHOLZ 2000, S. 13).....	32
Abbildung 22: Analytisches Aufstiegsmodell zur Zuordnung deskriptiver, diagnostischer, prädiktiver sowie präskriptive Verfahren der Datenanalyse (WIRAEUS ET AL. 2019, S. 171; GRÖGER 2015, S. 48). ....	33
Abbildung 23: a) Beispiel eines diskreten Bayesschen Netzwerkes; b) Bedingte Wahrscheinlichkeitstabelle des Ereignisses „Motor ausgefallen ( $X_{11}$ )“.....	35
Abbildung 24: Eingrenzung des Untersuchungsraumes anhand methodischer Ansätze.....	41
Abbildung 25: Grobkonzept zur Ausschussreduzierung in einer Batteriezellenproduktion. ...	57
Abbildung 26: Konzept einer Regelung nach DIN 55350-11.....	62
Abbildung 27: Konzeptbild eines experten- und datenbasierten Qualitätsmanagementsystems einer Batteriezellenproduktion.....	64
Abbildung 28: Qualitätsmanagementsystems einer Batteriezellenproduktion mit Hervorhebung des KPI-Systems. ....	66
Abbildung 29: Konzeptbild des KPI-Systems für die Batteriezellenproduktion. ....	67
Abbildung 30: Anwendung des kritischen Prozessfähigkeitsindex Cpk am Beispiel der Elektrodenlänge in Anlehnung an LINß 2013, S. 447. ....	69
Abbildung 31: Anwendung eines totalen kritischen Prozessfähigkeitsindex am Beispiel der Elektrolytmenge in Anlehnung an LINß 2013, S. 447.....	70
Abbildung 32: Struktur des Kennzahlensystems zur multivariaten Prozessfähigkeitsuntersuchung einer Batteriezellenproduktion nach KORNAS ET AL. 2019B sowie DE-FELIPE & BENEDITO 2017B.....	71

Abbildung 33: Beispiel eines Kennzahlensystems zur multivariaten Prozessfähigkeitsuntersuchung in der Batteriezellenproduktion. ....	73
Abbildung 34: Beispiel eines multivariaten Histogramms zur Unterstützung der Toleranzbestimmung. ....	73
Abbildung 35: Beispiel einer Korrelationserscheinung unterschiedlicher Produkt- oder Prozesstypen. ....	74
Abbildung 36 Gesamtansatz eines KPI-Systems für den Anlauf und Serienbetrieb einer Batteriezellenproduktion. ....	75
Abbildung 37: Qualitätsmanagementsystems einer Batteriezellenproduktion mit Hervorhebung des FMEA-basierten Bayesschen Netzwerkes. ....	77
Abbildung 38: Beispiel einer Anwendung von Bayesschen Netzwerken zur Fehler-Ursachen- Analyse in der Batteriezellenproduktion. ....	78
Abbildung 39: Beispiel zur Beschreibung der Fehlerfolgswahrscheinlichkeit. ....	81
Abbildung 40: Beispielhaftes Bayessche Netzwerk inkl. bedingter Wahrscheinlichkeitstabelle. ....	83
Abbildung 41: Exemplarische Anwendung der Noisy-OR Gates. ....	84
Abbildung 42: Beispiel einer Inferenz zur Fehler-Ursachen-Analyse in Anlehnung an die Berechnung aus Anhang 8.2. ....	85
Abbildung 43: Aggregierungsknoten zur Reduzierung bedingter Wahrscheinlichkeitstabellen. ....	87
Abbildung 44: Beispiel zur Verdeutlichung von Inkonsistenzen in Bayesschen Netzwerken. ....	88
Abbildung 45: a) Exemplarisches Bayessches Netzwerk zur Berechnung von Inkonsistenzen; b) Darstellung von Leak-Nodes in Bayesschem Netzwerk ausgehend vom Netzwerk aus Abbildung a).....	90
Abbildung 46: Grundlegende Struktur eines evolutionären Algorithmus (POHLHEIM 2013, S. 8). ....	93
Abbildung 47: Veranschaulichung der Suche nach einem konsistenten Netzwerk (nach DÖBEL ET AL. 2018, S. 50). ....	94
Abbildung 48: Vorgehen zur Konsistenzprüfung und Korrektur komplexer Bayesscher Netzwerke. ....	94

Abbildung 49: Qualitätsmanagementsystem einer Batteriezellenproduktion mit Hervorhebung der Self-Service Data Analytics. ....	99
Abbildung 50: Konzeptbild der Self-Service Data Analytics. ....	101
Abbildung 51: Prozessphase zur Datenselektion. ....	103
Abbildung 52: Beispiel einer Datentransformation (aus YAO ET AL. 2018, S. 7). ....	106
Abbildung 53: Schematische Darstellung des AutoML-Prozessmodells (in Anlehnung an YAO ET AL. 2018, S. 2 und KATZ ET AL. 2016, S. 979). ....	107
Abbildung 54: Prozessablauf zur synergetischen Verknüpfung der Self-Service Data Analytics und des Bayesschen Netzwerkes. ....	111
Abbildung 55: Architektur der prototypischen Implementierung. ....	114
Abbildung 56: Schematische Abbildung des Materialstroms einer Batteriezellenproduktion (in Anlehnung an SCHÖNEMANN 2017, S. 70). ....	116
Abbildung 57: Produkt- und Prozessmodell der prototypischen Implementierung. ....	118
Abbildung 58: Ausschnitt der prototypischen Implementierung für den Betrachtungsumfang einzelner Batteriezellen. ....	121
Abbildung 59: Ausschnitt der prototypischen Implementierung für den Betrachtungsumfang einer Charge. ....	122
Abbildung 60: Ausschnitt eines multivariaten Kennzahlensystems in Anlehnung an KORNAS ET AL. 2019B, S. 80. ....	123
Abbildung 61: Prototypische Implementierung der Fehler-Ursachen Analyse (KIRCHHOF ET AL. 2020). ....	124
Abbildung 62: Ausprägungsformen von Ursachen-Wirkzusammenhängen ....	125
Abbildung 63: Prototypische Implementierung eines visualisierten Bayesschen Netzwerkes. ....	125
Abbildung 64: Prototypische Implementierung einer Korrelationsanalyse als Teil der Phase des Datenverständnisses. ....	127
Abbildung 65: Prototypische Implementierung eines Histogramms zur Festlegung von Spezifikationen. ....	128
Abbildung 66: Prototypische Implementierung der Modellierung auf Basis von AutoML. ....	129
Abbildung 67: Darstellung des im Fallbeispiel betrachteten Prozesskettenabschnittes. ....	133

Abbildung 68: Qualitätsregelkarte als Teil des KPI-Systems zur Überwachung der Kapazität von produzierten Chargen. ....	134
Abbildung 69: Initiales Fehlernetzwerk der Zellassemblierung und Zellaktivierung (aus KIRCHHOF ET AL. 2020). ....	135
Abbildung 70: Initiales Fehlernetzwerk mit hervorgehobenen inkonsistenten Fehlerknoten. ....	136
Abbildung 71: Darstellung der inkonsistenten Fehlerknoten bezogen auf die Anzahl an Elternknoten. ....	137
Abbildung 72: a) Relative Änderung der Kennzahlen der Auftretenswahrscheinlichkeiten; b) Relative Änderung der Fehlerfolgewartrscheinlichkeiten $\pi_{i,j}$ . ....	137
Abbildung 73: Initiale Fehler-Ursachen-Analyse für das Fehlerbild „Formierung – Kapazität ist außerhalb des angegebenen Toleranzbereiches“ ....	138
Abbildung 74: Drilldown der Fehler-Ursachen-Analyse auf Basis weiterer Evidenzen. ....	139
Abbildung 75: Ergebnisse des AutoML für die Zielgröße Kapazität der Produktionscharge 165011. ....	140
Abbildung 76: Korrelationsanalyse ausgewählter Merkmale der Produktionscharge 165011. ....	141
Abbildung 77: Design Structure Matrix zur Sicherung experten- und datenbasierter Korrelationen. ....	148
Abbildung 78: Einordnungen verschiedener Ansätze zum Aufbau Bayesscher Netzwerke. ....	149
Abbildung 79: Übersetzung der Punktvorgabe von Auftretenswahrscheinlichkeit in A-priori-Wahrscheinlichkeit (KMENTA & ISHII 2004, S. 1031). ....	177
Abbildung 80: Beispiel multivariater Visualisierungen der deskriptiven Statistik (in Anlehnung an TAUSENDPFUND 2019, S. 205-221). ....	180
Abbildung 81: Beispiel eines Histogramms zur Bestimmung von Ausreißern (UAG = untere Ausreißergrenze, OAG= obere Ausreißergrenze, USG= untere Spezifikationsgrenze, OSG= obere Spezifikationsgrenze). ....	181





## Tabellenverzeichnis

Tabelle 3-1: Zusammenfassung der relevanten Forschungsansätze.....	53
Tabelle 4-1: Elemente zur Übertragung eines technischen Regelkreises auf einen Qualitätsregelkreis der Batteriezellenproduktion (in Anlehnung an KLOSTERMANN 2008, S. 53). ....	63
Tabelle 4-2: Übertragung einer FMEA zu einem Bayesschen Netzwerk in Anlehnung an KIRCHHOF ET AL. 2020.....	79
Tabelle 4-3: Übersetzungstabelle zu Bestimmung der A-priori-Wahrscheinlichkeit.....	81
Tabelle 4-4: Darstellung der finalen Datenmatrix aus Ausgangslage für die Modellierungsphase. ....	106
Tabelle 4-5: Vergleich Traditionelle Verfahren des Machine Learning und AutoML (in Anlehnung an YAO ET AL. 2018, S. 4).....	109
Tabelle 4-6: Vereinheitliche Fehlerbeschreibung für subjektive Prüfmethoden.....	117
Tabelle 8-1: Übersicht etablierter Qualitätskennzahlen nach LINß 2013, S. 457-458 und VMDA 2018.....	176
Tabelle 8-2: Übersicht der Prozessbewertungsgrößen DPMO, Prozessfähigkeiten, Yield und Six Sigma Level (LINß 2013, S. 626).....	177
Tabelle 8-3: Aufsummierung von Fehlerkombinationen zur Berechnung des Summanden $P(f1, f2, \neg f3)$ .....	179
Tabelle 8-4: Aufsummierung von Fehlerkombinationen zur Berechnung des Summanden $P(f1, \neg f2, \neg f3)$ .....	179

## Abkürzungsverzeichnis

A	Anforderungen
AutoML	Automated Machine Learning
CRISP-DM	Cross-Industry Standard Process for Data Mining
DPMO	Defects per Million Opportunities
EOl	End-of-Line
EOL	End-Of-Line
ETL	Extract, Transform, Load
FMEA	Fehlermöglichkeits- und -einflussanalyse
FTA	Fault Tree Analysis
GWP	Global Warming Potential
HiPot-Test	High-Potential-Test
KPI	Key Performance Indicator
M	Merkmal
NMC	Nickel-Mangan-Cobalt
OAG	Obere Ausreißergrenze
OSG	Obere Spezifikationsgrenze
QFD	Quality Function Deployment
RCA	Root Cause Analysis
SEI	Solid Electrolyte Interphase
SQL	Structured Query Language
U	Ursache
UAG	Untere Ausreißergrenze
UEG	Untere Eingriffsgrenze
UMG	Untere Mindestgrenze
USG	Untere Spezifikationsgrenze
UWG	Untere Warngrenze
W	Wirkung
XML	Extensible Markup Language
Z	Einzelziele
Zell-ID	Batteriezellen-Identifikationsnummer

## Formelverzeichnis

$AM$	Ausschussmenge
$B$	Bedeutung
$C$	Normierungsvektor des evolutionären Algorithmus
$C_{mpk}$	Total kritischer Prozessfähigkeitsindex
$C_{pk}$	Kritischer Prozessfähigkeitsindex
$DPMO$	Defects per Million Opportunities
$E$	Entdeckungswahrscheinlichkeit
$GM$	Gutmenge
$GT$	Gutteile
$MC_{pk}$	Multivariate Prozessfähigkeitsindizes
$NM$	Nacharbeitsmenge
$P(f_i)$	A-priori-Wahrscheinlichkeit des Fehlers $F_i$ mit dem Zustand $f_i$
$P(f_i)_{min}$	Mindest-A-priori-Wahrscheinlichkeit des Fehlers $F_i$ mit dem Zustand $f_i$
$P(f_i)$	A-priori-Wahrscheinlichkeit des Leak-Nodes
$P_{i,j}$	Fehlerfolgswahrscheinlichkeit zwischen einem Fehlerknoten $i$ und seinem Elternknoten $j$
$Pa(F_i)$	Elternknoten des Fehlers $F_i$
$PM$	Produzierte Menge
$PT$	Produzierte Teile
$q(p)$	Vektor der Kennzahlen der Auftretenswahrscheinlichkeiten und Fehlerfolgswahrscheinlichkeiten des alternativen Bayesschen Netzwerkes
$q_e$	Vektor der Kennzahlen der Auftretenswahrscheinlichkeiten und Fehlerfolgswahrscheinlichkeiten des initialen, expertenbasierten Bayesschen Netzwerkes
$R$	Korrelationskoeffizient nach Bravais-Pearson
$RPZ$	Risikoprioritätszahl
$R_{crit_s}$	Vereinigung der Teilmengen kritischer Prozessregionen für jede Produkteigenschaft $i \in \{1, \dots, n\}$
$T$	Zielwert
$W(f_i)$	Auftretenswahrscheinlichkeit des Fehlers $F_i$ mit dem Zustand $f_i$
$\alpha$	Hyperparameter
$\eta$	Anzahl der Inkonsistenzen eines Fehlernetzwerkes
$\phi$	Verteilungsfunktion der Normalverteilung



# 1 Einleitung

## 1.1 Motivation

Die fortschreitende Verknappung von Ressourcen, wachsendes Umweltbewusstsein und gesetzliche Regelungen sind Auslöser einer sich global vollziehenden Umgestaltung in Richtung nachhaltiger Mobilität. Eine Schlüsselrolle in dieser Umgestaltung kommt elektrifizierten Fahrzeugen zu. Sie gelten als effizient und lokal emissionsfrei (SCHOBLOCK 2013). In Verbindung mit erneuerbaren Energieträgern besitzen sie zudem das Potenzial, die mobilitätsbedingten Treibhausgasemissionen im Vergleich zu verbrennungsmotorischen Fahrzeugen zu verringern (DÉR ET AL. 2018, S. 74; BUNDESMINISTERIUM FÜR UMWELT, NATURSCHUTZ UND NUKLEARE SICHERHEIT 2019, S. 7). Das Potenzial spiegelt sich auch in einem weltweit prognostizierten Anstieg der Anzahl elektrifizierter Fahrzeuge wider, wie Abbildung 1 entnommen werden kann.




Abbildung 1: Anzahl elektrifizierter Fahrzeuge weltweit als Summe aus batterieelektrischen und Plug-In-hybriden Personenkraftwagen, Bussen und Lastkraftwagen (ZSW 2020; INTERNATIONAL ENERGY AGENCY 2019A; INTERNATIONAL ENERGY AGENCY 2019B.).

Das prognostizierte Wachstum wird dabei wesentlich durch die Weiterentwicklung von Batteriezellentechnologien bestimmt, da Batteriezellen sowohl aus technischer Sicht als auch aus der Kostenperspektive die elektrischen Fahrzeuge maßgeblich beeinflussen. Zusammen mit den notwendigen Systemkomponenten eines Hochvoltspeichers besitzen Batteriezellen einen durchschnittlich 38%-igen Anteil an den Gesamtkosten eines elektrischen Fahrzeuges (STATISTA 2020A). Zudem sind sie entscheidend für differenzierende Fahreigenschaften, da

sie Gesamtgewicht und abrufbare Spitzenleistung beeinflussen sowie Schnellladefähigkeit, Reichweite und Lebensdauer definieren (WÖHRLE 2013, S. 116).

Lithium-Ionen-Batteriezellen stellen derzeit die favorisierte Technologie für elektrische Fahrzeuge vieler Automobilhersteller dar, da sie eine hohe spezifische und volumetrische Energiedichte sowie eine hohe Zyklenlebensdauer aufweisen (YOSHIO 2009, S. 2). Eine der großen Herausforderungen stellt allerdings der Herstellungsprozess dar, welcher mit einem signifikant hohen Produktionsausschuss von 5–12% einhergeht (BRODD & HELOU 2013, S. 298; HANISCH ET AL. 2015). Der Produktionsausschuss beeinflusst nicht nur maßgeblich die Herstellungskosten, sondern wirkt insbesondere den genannten Potentialen der elektrischen Fahrzeuge entgegen, Emissionen zu verringern. Der hohe Einfluss des Produktionsausschusses auf die Kosten und Emissionen soll anhand des nachfolgenden Beispiels verdeutlicht werden. Unter der Annahme der Herstellkosten von 105 €/kWh<sup>1</sup> sowie einem Materialkostenanteil von 55%<sup>2</sup> kann ein Zellhersteller bei einem beispielhaften Produktionsvolumen von 21 GWh/Jahr<sup>3</sup> und einer beispielhaften Ausschussreduzierung von 8% auf 5% eine Materialkosteneinsparung von 53 Mio. €/Jahr erzielen. Gleichzeitig reduzieren sich dabei die energiebedingten CO<sub>2</sub>-Äquivalenten-Emissionen um 165.839,4 Tonnen<sup>4</sup>.

Die hohen Ausschüsse in der Produktion von Batteriezellen lassen sich auf die folgenden Komplexitätsmerkmale zurückführen:

- **Anzahl an Prozessarten:** Es liegen Prozesse vor, die sich unterschiedlichen Fachbereichen zuordnen lassen, wie bspw. der Elektrochemie, der Materialwissenschaft und der Fertigungstechnik (WÖHRLE 2013, S. 107; KORNAS ET AL. 2020, S. 2). Dies führt zu einer Heterogenität in der Erfahrung und dem Wissen von Experten und somit potenziell zu Schnittstellenproblematiken.
- **Innovationsgrad:** Die Batteriezellenproduktion weist produkt- und prozessseitig eine Vielzahl an Forschungs- und Entwicklungsfeldern auf (KAMPKER 2014, S. 44). Dies

---

<sup>1</sup> Preis für Lithium-Ionen-Batteriezellen im Jahr 2019 nach STATISTA 2020B

<sup>2</sup> Bezogen auf die Gesamtkosten mit NMC622 Zellmaterial (NELSON ET AL. 2019, S. 106)

<sup>3</sup> Entspricht dem Produktionsvolumen der Fa. *Contemporary Amperex Technology (CATL)* im Jahr 2019 für NMC622 Zellmaterial (aus: <https://www.catlbattery.com/en/web/index.php/about/status>)

<sup>4</sup> Unter der Annahme energiebedingter Emissionen in der Batteriezellenproduktion von 87 kg CO<sub>2</sub>Äq./kWh, NMC622 Zellmaterial und einem Strommix von ca. 0,5 kg CO<sub>2</sub> Äq./kWh (aus FORSCHUNGSSTELLE FÜR ENERGIEWIRTSCHAFT 2019, S. 6)

führt dazu, dass Produkte und Prozesse durch ein unzureichendes Maß an Standardisierungen charakterisiert sind (KAMPKER 2014, S. 50). Dies spiegelt sich einerseits in der hohen Varianz von Zellformaten wider, wie bspw. Rundzellen, prismatische Zellen oder Pouch-Zellen (vgl. WÖHRLE 2013, S. 112). Zudem können Fertigungsschritte auf grundsätzlich verschiedenen Konzepten aufbauen. Als Beispiel sei die Herstellung der Elektrodenpaste zu nennen, welche diskontinuierlich in einem Planetenmischer oder kontinuierlich in einem Extruder erfolgen kann (vgl. DREGER ET AL. 2015). Der hohe Neuheitsgrad führt zu Unsicherheiten in der Auslegung einzelner Prozesse und nicht zuletzt, aufgrund der unterschiedlichen Prozessarten, zu einer Herausforderung in der Auslegung einer gesamthaften Produktion (KAMPKER 2014, S. 44).

- **Quantität der Prozessschritte und Prozesskettenelemente:** Es liegt eine hohe Anzahl an Prozessschritten vor. Prozessschritte können dabei eine Vielzahl an Prozesskettenelementen umfassen. Diese beschreiben prozessbezogene Eingangs- und Ausgangsgrößen, wie bspw. die Wickelgeschwindigkeit oder spezifische Energiedichte (vgl. WESTERMEIER 2016, S. 113-116 sowie die Definition in Abschnitt 2.2.1).
- **Ursachen-Wirkzusammenhänge:** Es herrschen wechselseitige Beziehungen zwischen Prozesskettenelementen. Prozesskettenelemente wirken nicht nur auf Folgeprozesse, sondern können sich auch prozessübergreifend, direkt oder indirekt auf die Qualitätseigenschaften einer Batteriezelle auswirken (vgl. WESTERMEIER 2016, S. 124). Eine räumliche und zeitliche Trennung von Prozessschritten erschwert die Identifikation dieser Beziehungen.
- **Sensitivität:** Die Prozesskettenelemente und Ursachen-Wirkzusammenhänge weisen eine hohen Sensitivität auf, welche nach TASCHNER definiert werden kann als eine Empfindlichkeit zwischen Eingangs- und Ausgangsgrößen (TASCHNER 2017, S. 122). Geringe Abweichungen der Eingangsgrößen können die Produktqualität maßgeblich beeinflussen. Dies führt zu großer Unsicherheit in der Auslegung der Prozesskette.

Die auf die Batteriezellenproduktion wirkenden Komplexitätsmerkmale und insbesondere der Einfluss der Ursachen-Wirkzusammenhänge soll mithilfe von Abbildung 2 verdeutlicht werden. Ursachen-Wirkzusammenhänge führen demnach zu Herausforderungen in der Qualitätsprüfung, da Fehler nicht nur isoliert in einzelnen Prozessschritten, sondern im Zusammenwirken mehreren Einflussfaktoren auftreten können. Darüber hinaus beeinträchtigt das fehlende Verständnis für Ursachen-Wirkzusammenhänge auch die Durchführung einer Fehler-Ursachen-Analyse, da komplexe, prozessübergreifende Einflussfaktoren vorliegen, die gesamthaft zu betrachten sind. Die verschiedenen Prozessarten und die hohe Anzahl an Prozessschritten



und Prozesskettenelementen erschweren die Qualitätsprüfung und Fehler-Ursachen-Analyse zusätzlich.

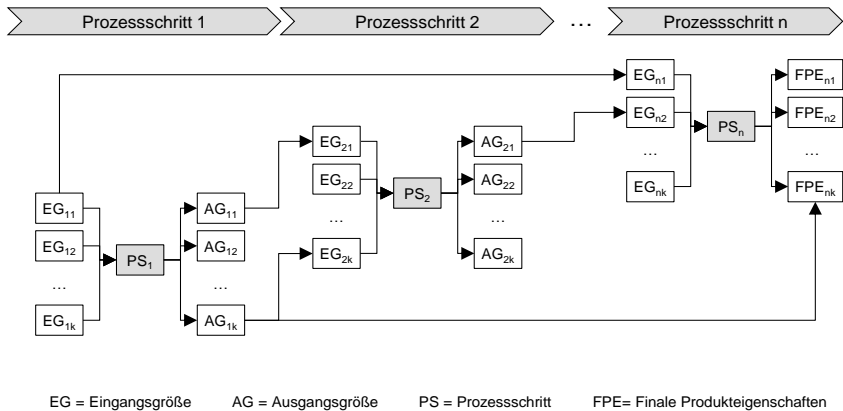


Abbildung 2: Exemplarische Darstellung einer komplexen Prozesskette.

## 1.2 Zielsetzung und Vorgehensweise

Die Ausschussreduzierung in der Batteriezellenproduktion repräsentiert einen wesentlichen Hebel zur Senkung der Kosten elektrischer Fahrzeuge und produktionsbedingter CO<sub>2</sub>-Emissionen. Abgeleitet aus der dargelegten Motivation ist das Ziel dieser Forschungsarbeit die Entwicklung eines Qualitätsmanagementsystems, welches auf Basis geeigneter Methoden der Qualitätsprüfung und der Fehler-Ursachen-Analyse eine Ausschussreduzierung in der Produktion von Batteriezellen bewirken soll.

Die Batteriezellenproduktion ist gekennzeichnet durch einen signifikant langen Produktionsanlauf von 48 Monaten<sup>5</sup>, welcher auf die fehlende Produktionserfahrung zurückgeführt werden kann (NATIONALE PLATTFORM ELEKTROMOBILITÄT 2016, S. 26). Der Verband Deutscher Maschinen- und Anlagenbau e.V. (VMDA) sieht zudem auch die

<sup>5</sup> Abschätzung für den Aufbau einer neuen Zellfertigung (Zeitraum ab B-Musterphase bis Fabrikinbetriebnahme) nach NATIONALE PLATTFORM ELEKTROMOBILITÄT 2016, S. 34

Skalierbarkeit einer Serienproduktion von Batteriezellen als Kernherausforderung (VDMA 2018, S. 10). Das zu entwickelnde Qualitätsmanagementsystem ist so auszulegen, dass es sowohl in der Anlaufphase als auch im Serienbetrieb einer Batteriezellenproduktion verwendet werden kann. Es soll eine industriell anwendbare Methode darstellen, die ausgehend vom Produktionsanlauf, in welchem nur wenig Produkt- und Prozesswissen vorliegt, bis hin zur Serienproduktion eine kontinuierliche Qualitätsverbesserung unterstützt. Dabei soll das Qualitätsmanagementsystem von unterschiedlichen Mitarbeitern, wie bspw. Anlagenbedienern, Technologen oder Entwicklern, genutzt werden können.

Diese Forschungsarbeit ist in sechs Kapitel untergliedert.

## Kapitel 2

Kapitel 2 dient einer Vorstellung der **Batteriezellenproduktion und des Qualitätsmanagements**. Zunächst erfolgt eine Einführung in den Aufbau, die Funktionsweise sowie die Prozesskette zur Herstellung von Lithium-Ionen-Batteriezellen. Im zweiten Teil des Kapitels werden die im Kontext dieser Arbeit stehenden Themenfelder Qualität, Komplexität, Kausalität und fertigungstechnische Prozessketten beschrieben. Darauf aufbauend werden etablierte Methoden des Qualitätsmanagements diskutiert, wobei auch auf Ansätze der Datenanalyse sowie statistische Verfahren eingegangen wird.

## Kapitel 3

Kapitel 3 beschreibt den **Stand der Forschung** im Kontext des Qualitätsmanagements. Auf Basis eingeführter Bewertungskriterien erfolgt eine strukturierte Analyse von Forschungsarbeiten. Dabei werden insbesondere Methoden zur Analyse von Ursachen-Wirkzusammenhängen als auch Reifegrade von Qualitätsmanagementsystemen diskutiert.

## Kapitel 4

Abgeleitet aus den identifizierten Forschungslücken erfolgt in Kapitel 4 die Entwicklung eines **Qualitätsmanagementsystems für die Produktion von Batteriezellen** sowie die Vorstellung und Detaillierung der darin enthaltenen zentralen Lösungsbausteine. Der Nachweis über die Verknüpfung der Lösungsbausteine wird mithilfe einer prototypischen Implementierung erbracht.

## Kapitel 5

Ausgehend von der prototypischen Implementierung erfolgt in Kapitel 5 eine **exemplarische Anwendung** des entwickelten Qualitätsmanagementsystems und seiner Lösungsbausteine anhand eines Fallbeispiels.

## Kapitel 6

Kapitel 6 präsentiert die **Zusammenfassung** der Forschungsergebnisse. Mithilfe der kritischen Würdigung sollen zudem der Stellenwert und die Grenzen des entwickelten Konzepts aufgezeigt werden. Diese bilden die Grundlage eines anschließend diskutierten **Ausblicks**.

## 2 Batteriezellenproduktion und Qualitätsmanagement

In Unterkapitel 2.1 erfolgt zunächst eine Beschreibung des Aufbaus und der Funktionsweise einer Lithium-Ionen-Batteriezele. Zudem werden die in einer Batteriezellenproduktion vorliegenden Komplexitätsmerkmale hervorgehoben, weshalb der Herstellungsprozess im Detail beschrieben wird. Dadurch werden insbesondere relevante Hintergrundinformationen bereitgestellt, die für das Verständnis der im Verlauf der Arbeit beschriebenen Beispiele notwendig sind. In Unterkapitel 2.2, erfolgt eine Einführung in das Themenfeld des Qualitätsmanagements im Kontext fertigungstechnischer und verfahrenstechnischer Prozessketten. In diesem Zusammenhang werden die Begrifflichkeiten Qualität, Komplexität und Kausalität diskutiert. Zudem werden etablierte Methoden zur Zuverlässigkeitsanalyse und Prozessführung sowie der Statistik und der Datenanalyse vorgestellt.

### 2.1 Batteriezellenproduktion

#### 2.1.1 *Aufbau und Funktionsweise von Lithium-Ionen-Batteriezellen*

Lithium-Ionen-Batteriezellen repräsentieren einen elektrochemischen Energiespeicher. Die grundlegenden Komponenten einer Lithium-Ionen-Batteriezele bilden, wie in Abbildung 3 dargestellt, die positive und negative Elektrode, die sich in einem ionenleitfähigen Elektrolyten befinden und durch einen Separator isoliert werden. (KWADE ET AL. 2018, S. 290)

Der Lade- und Entladevorgang einer Lithium-Ionen-Batteriezele ist charakterisiert durch die Bewegungen von Ionen, welche sich in den Aktivmaterialien der Elektroden ein- bzw. auslagern. Im Entladefall stellt die negative Elektrode die Anode und die positive Elektrode die Kathode dar. Obwohl die Bezeichnung der Anode und Kathode über den Reduktions-/Oxidationsprozess definiert ist, bleibt sie auch beim Ladevorgang bestehen. Wie Abbildung 3 entnommen werden kann, bewegen sich beim Entladevorgang Lithium-Ionen von der Kathode (negative Elektrode) durch einen Elektrolyten und einen Separator zur Anode (positiv geladene Elektrode). Gleichzeitig fließen Elektronen über einen äußeren Leiterkreis von der Kathode zur Anode. Dieser äußere Leiterkreis kann als Stromquelle betrachtet werden. Beim Ladevorgang verläuft der beschriebene Prozess umgekehrt. Hierbei bewegen sich Lithium-Ionen von der Anode durch einen Elektrolyten und einen Separator zur Kathode. Der Separator stellt eine mikroporöse Membran dar, welche einen Ionentransport ermöglicht und die beiden Elektroden voneinander elektrisch isoliert. (LEUTHNER 2013, S. 14–16, S. 21)

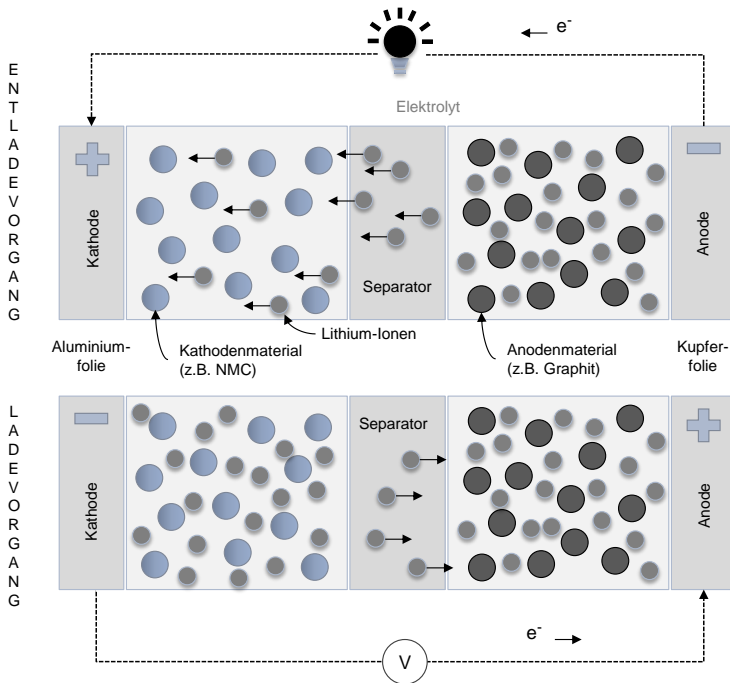


Abbildung 3: Grundlegender Aufbau einer Lithium-Ionen-Batteriezelle

(nach SCHÖNEMANN 2017, S. 12).

Die Elektroden bestehen aus metallischen Trägerfolien, die mit einem Aktivmaterial beschichtet werden. Die Trägerfolien der Anoden werden aus Kupfer und die der Kathoden aus Aluminium hergestellt. Die Zusammensetzung des auf den Trägerfolien befindlichen Aktivmaterials beeinflusst die Kapazität, Sicherheit und Lebensdauer einer Lithium-Ionen-Batteriezelle (LEUTHNER 2013, S. 16-17). Grundlegend für die Funktionseigenschaften ist ebenfalls der Benetzungsradius der Aktivmaterialien mit dem Elektrolyten, da der Elektrolyt eine Voraussetzung bildet, dass sich Lithium-Ionen zwischen den Elektroden bewegen können (KNOCH 2017, S. 72). Zudem müssen die Partikel der Beschichtung untereinander und mit den Trägerfolien der Kathode bzw. Anode verbunden sein (LEUTHNER 2013, S. 18).

Um einen Eintritt von Feuchtigkeit zu vermeiden, besitzen Lithium-Ionen-Batteriezellen ein metall- oder kunststoffbasiertes Gehäuse. Zylindrische Zellen, prismatische Zellen und Flachzellen (engl. Pouch Cell) stellen in der Industrie etablierten Bauformen von Batteriezellen dar (vgl. Abbildung 4) (KWADE ET AL. 2018, S. 291). Der zylindrische Zelltyp weist einen gewickelten

und der prismatische Zelltyp einen gewickelten oder gestapelten Zellkörper auf. Beide Zelltypen werden mit einem festen Gehäuse (Hardcase) aufgebaut. Flachzellen besitzen einen Elektrodenstapel (Stack) aus Einheitszellen. Dabei besteht jede Einheitszelle aus einem Kathodenblatt, Separatorfolie sowie Anodenblatt. Die Abfolge von Kathode, Separator und Anode findet sich auch in den gewickelten Zellkörpern wieder. (WÖHRLE 2013, S. 111-112; KAMPKER ET AL. 2013, S. 241)

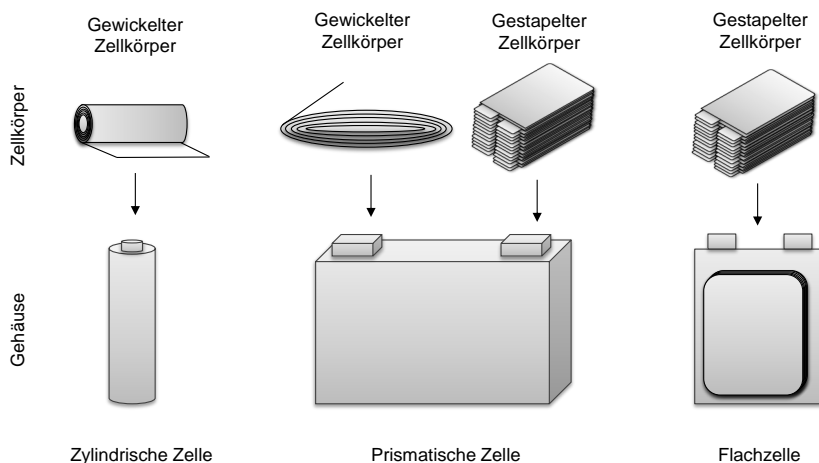


Abbildung 4: Etablierte Bauformen von Lithium-Ionen-Batteriezellen (in Anlehnung an WÖHRLE 2013, S. 112 und PETTINGER 2013, S. 227).

### 2.1.2 Prozesskette zur Herstellung von Lithium-Ionen-Batteriezellen

Ausgehend von den in Abbildung 4 dargestellten Bauformen lassen sich unterschiedliche fertigungstechnische Prozessketten für die Herstellung von Lithium-Ionen-Batteriezellen ableiten. Da sich die exemplarischen Anwendungen dieser Arbeit auf prismatische Lithium-Ionen-Batteriezellen beziehen, soll der dazugehörige Herstellungsprozess nachfolgend im Detail beschrieben werden. Die in dieser Arbeit zur Herstellung von prismatischen Lithium-Ionen-Batteriezellen zugrundeliegende Prozesskettenstruktur ist Abbildung 5 zu entnehmen. Sie gliedert sich in die Prozesskettenabschnitte Elektrodenherstellung, Zellmontage und Aktivierung. (KWADE ET AL. 2018, S. 292)




Abbildung 5: Prozesskettenstruktur prismatischer Lithium-Ionen-Batteriezellen.

Den ersten Prozessschritt der Elektrodenherstellung bildet das Mischen. Durch das Dispergieren unterschiedlicher Komponenten, wie Aktivmaterialien, Leitruf, Bindemittel, Lösemittel und Additive, entsteht eine Paste, welche als Slurry bezeichnet wird. Eine Umhüllung der Aktivmaterialien mit dem Leitruf und die Erzeugung einer homogenen Masse repräsentieren wesentliche Anforderungen an die Slurry und können mithilfe genauerster Dosierungen sowie definierter Mischprinzipien und Prozessparameter umgesetzt werden. Es sind zeitliche Veränderungen der Eigenschaften einer Slurry zu berücksichtigen, weshalb eine schnelle Weiterverarbeitung im Beschichtungsprozess erforderlich ist. Beim Beschichten handelt es sich um ein Auftragen der Slurry auf die Trägerfolien. Da die Massenbeladung die Eigenschaften einer Batterie zelle beeinflussen, erfolgt dieser Prozessschritt unter hoher Präzision. Der Beschichtungsprozess zeigt zudem eine starke Abhängigkeit von dem vorgelagerten Mischprozess, da dieser den Zusammenhalt der Elektrodenstruktur und die Adhäsion der Slurry maßgeblich beeinflusst. Nach der Beschichtung erfolgt die Trocknung der Slurry, sodass das enthaltene Lösemittel verdampfen kann. Im Anschluss wird die aufgetragene Schicht im Prozessschritt Kalandern verdichtet. Dabei wird das Ziel verfolgt, eine vorgegebene Porosität bei gleichzeitiger Erhöhung der Haftung zwischen Beschichtung und Trägerfolie zu erzeugen. Im letzten

Prozessschritt werden die Elektroden auf eine geforderte Bahnbreite geschnitten. (KWADE ET AL. 2018, S. 292-295; KAMPKER ET AL. 2013, S. 238-240)

Feuchte, die in Lithium-Ionen-Batteriezellen eindringt, kann zu unerwünschten Nebenreaktionen und somit zu veränderten Zelleigenschaften führen. Um den Feuchteanforderungen gerecht zu werden, findet die Zellmontage und Teile der Elektrodenherstellung unter Trockenatmosphäre statt (SIMON 2013, S. 251). Da die Elektrodenherstellung räumlich und zeitlich von der Zellmontage getrennt ist, wird in einem ersten Prozessschritt versucht, mithilfe eines Vakuumentrockners einem möglichen Wassereintrag entgegenzuwirken. Beim anschließenden Wickelprozess werden Kathoden-, Anoden- und Separatorbahnen um ein Wickelschwert geführt. Der hieraus entstehende Elektrodenkörper wird auch als Jelly Roll bezeichnet. Die Wickelgeschwindigkeit, die verbaute Anoden- und Kathodenlänge sowie die Bahnspannung repräsentieren dabei Kenngrößen, welche die Batteriezelle qualitativ beeinflussen können. Auch wirken diese Kenngrößen auf das nachfolgende Verpressen, in welchem das Ziel verfolgt wird, die Dichte des Zellkörpers zu erhöhen. Im nächsten Prozessschritt, dem Ultraschallschweißen, erfolgt die Kontaktierung zwischen dem Zellkörper und Stromableiter. Letzterer bildet einen Teil der Deckelbaugruppe. Durch einen Hochvolttest (engl. High-Potential Test, kurz HiPot-Test) werden fehlerhafte Zellen identifiziert. Zusammen mit Kunststoffhalterungen, die der elektrischen Isolierung dienen, wird der Zellkörper in einem darauffolgenden Prozessschritt in das Gehäuse montiert. Mithilfe eines Schweißprozesses kann in einem weiteren Schritt das Gehäuse an die Deckelbaugruppe gefügt werden. Es folgt ein zusätzlicher Hochvolttest sowie ein Helium-Lecktest, um die Dichtheit der Batteriezelle zu prüfen. Der Prozessschritt Elektrolytfüllen besitzt besondere Relevanz, da wie bereits erwähnt der Benetzungsgrad der Elektroden mit dem Elektrolyten maßgeblich für die Funktionsweise einer Lithium-Ionen-Batteriezelle ist. Neben den Einstellparametern des Befüllvorganges bestimmen auch der Wickelprozess, das Pressen sowie das Ultraschallschweißen den Benetzungsgrad, da hierüber die Fließvorgänge des Elektrolyten in den Zellkörper beeinflusst werden können (KNOCH 2017, S. 104). (PETTINGER 2013; KAMPKER ET AL. 2013)

Bevor die an der Deckelbaugruppe eingebrachte Elektrolyt-Befüllöffnung versiegelt wird, findet der Vorladeprozess statt. Hierbei wird die Lithium-Ionen-Batteriezelle erstmalig teilweise geladen und entladen. Es bildet sich dabei eine Passivierungsschicht (Solid Electrolyte Interphase Layer, kurz SEI), welche maßgeblich die Zyklenstabilität, Lebensdauer und Leistung einer Lithium-Ionen-Batteriezelle beeinflusst (WURM ET AL. 2013, S. 51). Ein Versiegeln der Elektrolyt-Befüllöffnung findet erst nach dem Vorladen statt, da zu Beginn der SEI-Bildung Gase entstehen, welche entweichen müssen. Der letzte Prozessschritt in der Produktion von Lithium-Ionen-Batteriezellen ist die Formierung. Durch ein vollständiges Laden wird die SEI-Bildung



abgeschlossen. Gleichzeitig lassen sich qualitätsrelevante Eigenschaften, wie bspw. die Kapazität einer Lithium-Ionen-Batteriezele, ermitteln. (KWADE ET AL. 2018; KAMPKER ET AL. 2013; WURM ET AL. 2013)

## 2.2 Qualitätsmanagement in Prozessketten

In der DIN EN ISO 9000 wird das Qualitätsmanagement definiert als „[...] aufeinander abgestimmte Tätigkeiten zum Leiten und Lenken einer Organisation bezüglich Qualität“. Die Themenfelder Qualitätsverbesserung, Qualitätssicherung, Qualitätslenkung, Qualitätsplanung sowie Qualitätspolitik und Qualitätsziele lassen sich, wie Abbildung 6 zu entnehmen ist, dem Qualitätsmanagement zuordnen.




Abbildung 6: Untergeordnete Themenfelder des Qualitätsmanagements. (DIN EN ISO 9000, S. 14)

Das Wort Qualität leitet sich aus dem lateinischen „qualitas“ bzw. „qualis“ ab, was mit „wie beschaffen?“ übersetzt werden kann (DIN 55350-11). Der Begriff definiert sich nach DIN EN ISO 9000 als „[...] Grad, in dem ein Satz inhärenter Merkmale Anforderungen erfüllt [...]“ und beschreibt die „[...] realisierte Beschaffenheit einer Einheit [...]“. Als Einheit wird im Kontext fertigungstechnischer Prozessketten ein Produkt oder Prozess verstanden. Die Qualität kann kontinuierliche sowie diskret ausdrückbare Bewertungsmöglichkeiten enthalten und misst sich an der geforderte Beschaffenheit (DIN 55350-11, S. 11).

Eine Umsetzung von Qualitätsmanagement bedeutet nicht nur Produkte in Sollqualität herzustellen, sondern Prozesse in Sollqualität zu regeln und kontinuierlich zu verbessern. Hierfür können, in Analogie zur Regelungstechnik, sogenannte Qualitätsregelkreise hinzugezogen werden. Diese lassen sich definieren als „[...] abgeschlossene technologisch-organisatorische Wirkungsabläufe in einem Prozess zur Schaffung eines Qualitätsproduktes [...]“ (LINIG 2013,

S. 20). Unterschieden wird zwischen kleinen und großen Qualitätsregelkreisen. Kleine Qualitätsregelkreise nehmen einen unverzögerten Einfluss auf die Qualitätsmerkmale einzelner Fertigungsschritte. Große Qualitätsregelkreise unterstützen eine nachträgliche Überprüfung und Qualitätsbestätigung mehrere Fertigungsschritte. Sie besitzen somit einen indirekten Einfluss auf zukünftige Erzeugnisse. Eine detaillierte Beschreibung der Funktionsweise und der Elemente eines Qualitätsregelkreises erfolgt in Unterkapitel 4.2. Im Weiteren sei auch auf die Beschreibung von Qualitätsregelkreisen in LINß verwiesen. (LINß 2013, S. 23)

### 2.2.1 Prozessketten

Nach DIN EN ISO 9000 ist ein Prozess definiert als ein „Satz zusammenhängender oder sich gegenseitig beeinflussender Tätigkeiten, der Eingaben zum Erzielen eines vorgesehenen Ergebnisses verwendet“. Der Begriff *Prozesskette* lässt sich nach SCHÄFER in unterschiedlichen Zusammenhängen verwenden, wie bspw. in der Produktgestaltung oder im Bereich der Daten- und Informationsverarbeitung (SCHÄFER 2003, S. 3). Im Kontext dieser Arbeit beschreibt der Begriff *Prozesskette* eine Folge von verfahrens- und fertigungstechnischen Prozessen zur Herstellung von Batteriezellen. Eine Prozesskette weist nach EICHGRÜN folgende Merkmale auf (EICHGRÜN 2003):

- Es liegt eine definierte Reihenfolge miteinander verbundener Einzelprozesse vor, wobei Ausgangsgrößen eines jeweiligen Prozesses einen Teil der Eingangsgrößen eines nachfolgenden Prozesses bilden können.
- Als gemeinsame Systemkomponente eines jeden Einzelprozesses wird das Produkt (Batteriezelle) in seinem jeweiligen Zustand betrachtet.
- Es ist eine schrittweise Zustandsänderung des Produktes vorhanden. Zwischen- oder Endzustände des Produktes können somit durch eine Vielzahl von Einflussgrößen definiert werden.

In Anlehnung an WESTERMEIER werden die in einem Prozess relevanten Eingangs- und Ausgangsgrößen übergeordnet als *Prozesskettenelemente* beschrieben (WESTERMEIER 2016, S. 70, S. 90). *Prozesskettenelemente* lassen sich, wie Abbildung 7 entnommen werden kann, in *Eingangsproduktmerkmale*, *Zwischenproduktmale* und *finale Produkteigenschaften* kategorisieren (vgl. THIEDE ET AL. 2019, S. 4 und WESTERMEIER 2016, S. 70).

*Eingangsproduktmerkmale* werden durch Prozessparameter oder Störgrößen repräsentiert. Prozessparameter beschreiben technisch beeinflussbare Anlagenparameter, wie bspw. die Wickelgeschwindigkeit zur Herstellung eines prismatischen Zellkörpers (THIEDE ET AL. 2019,



thematischen Einstieg in den Produktionsanlauf. Dabei soll insbesondere Bezug auf die Anlaufphasen einer Batteriezellenproduktion genommen werden.

In den Arbeiten von DYCKHOFF ET AL., FLEISCHER ET AL., ULRICH und GLEICH ET AL. wird ersichtlich, dass keine Konsistenz in der Begriffsdefinition eines Produktionsanlaufes vorliegt (DYCKHOFF ET AL. 2012, S. 1429 ff.; FLEISCHER ET AL. 2005; ULRICH 2016, S. 15 ff.; GLEICH ET AL. 2012). Gleichwohl lassen sich folgende übereinstimmende Merkmale identifizieren, welche einer Beschreibung des Produktionsanlaufes dienen sollen:

- Der Produktionsanlauf beschreibt ein Bindeglied zwischen dem Entwicklungsprozess und einem Serienbetrieb.
- Der Produktionsanlauf besteht aus mehreren zeitlich voneinander getrennten Phasen.
- Im Rahmen des Produktionsanlaufes wird das Ziel verfolgt, eine maximale und stabile Ausbringung von Produkten zu erreichen. Das Erreichen dieser Ausbringung wird als Kammlinie bezeichnet.

Um den Produktionsanlauf im Kontext einer Batteriezellenproduktion zu strukturieren, wird das in der Abbildung 8 dargestellte Phasenmodell vorgeschlagen. Dabei wird insbesondere Bezug auf die im Vergleich zu einer Serienproduktion differenzierenden Merkmale genommen.




Abbildung 8: Produktionsanlauf und Serienproduktion einer Batteriezellenfertigung (in Anlehnung an DYCKHOFF ET AL. 2012, S. 1430).

Die *Prototypenproduktion* beginnt nach dem Aufbau und der Inbetriebnahme der Produktionsanlagen. Im Fokus steht die iterative Produkt- und Prozessentwicklung unterschiedlicher Batteriezellentypen mit dem Ziel, die jeweiligen Funktionseigenschaften zu bewerten. Eine solche Ausrichtung erfordert eine produkt- und prozessflexible Auslegung der Prozesskette, weshalb ein geringer Automatisierungsgrad vorliegt. Der geringe Automatisierungsgrad, ein erhöhter Beschaffungsaufwand für Materialien und erhöhte Kosten für Komponenten führen dazu, dass in dieser Prozessphase nur eine begrenzte Stückzahl an Batteriezellen hergestellt werden kann.

Im Rahmen der Prototypenproduktion erfolgt die Bestätigung des Produktkonzepts. Anschließend soll mithilfe der *Pilotlinienproduktion* ein Nachweis der Prozessfähigkeit erbracht werden. Hieraus resultiert die Anforderung an eine Steigerung der Produktionsstückzahl und damit einhergehend eine Erhöhung des Automatisierungsgrades. Im Fokus der Pilotlinienproduktion steht somit die Prozessoptimierung.

Die *Serienproduktion* lässt sich in *Hochlauf* und *Marktphase* unterteilen. Der Zeitraum zwischen der Inbetriebnahme und der Endabnahme kundenfähiger Batteriezellen kann als Hochlauf bezeichnet werden (NAGEL 2011, S. 6). Die Marktphase ist neben der Produktion kundenfähiger Batteriezellen insbesondere durch einen stabil laufenden Produktionsprozess gekennzeichnet, welcher darauf abzielt, die Kammlinie möglichst schnell zu erreichen.

Eine Besonderheit stellt auch die Skalierung einer Batteriezellenproduktion dar. Aufgrund der genannten Komplexitätsmerkmale und des hieraus resultierenden, hohen Produktionssauschusses (vgl. Unterkapitel 1.1) erfolgt die Skalierung einer Batteriezellenproduktion anhand der Duplikation einer stabil laufenden Fertigungsline (NATIONALE PLATTFORM ELEKTROMOBILITÄT 2016, S. 35).

### 2.2.3 Komplexität in Prozessketten

Für den Begriff Komplexität liegt keine einheitliche Definition vor, da diese stark von der zu betrachtenden Wissenschaftsdisziplin abhängt (ZIELOWSKI 2006, S. 28). Die Subbegriffe *Elemente* und *Relationen* bilden allerdings eine Schnittmenge in den verschiedenen Definitionen (vgl. SKIRDE ET AL. 2015, S. 12. und ZIELOWSKI 2006, S. 23). Im Kontext der vorliegenden Arbeit sind unter dem Begriff *Elemente* die in Abbildung 7 verdeutlichten Prozesskettenelemente zu verstehen, welche in Eingangs- und Zwischenproduktmerkmale sowie finale Produkteigenschaften kategorisiert werden können. Die *Relationen* können als Ursachen-Wirkzusammenhänge betrachtet werden. Wie in Abbildung 9 dargestellt, können diese unterschiedliche Ausprägungsformen besitzen. Unterschieden wird demnach zwischen direkten, indirekten,

einfachen und mehrfachen Ursachen-Wirkzusammenhängen. Es sei hervorzuheben, dass Ursachen-Wirkzusammenhänge entscheidende Komplexitätstreiber darstellen, auch weil Kombinationen der genannten Ausprägungsformen möglich sind (WESTERMEIER 2016, S. 14).

Zudem werdend durch WESTERMEIER weitere Komplexitätsfaktoren definiert, die in einer Prozesskette vorliegen können (WESTERMEIER 2016, S. 12-13). Diese wären im Einzelnen:

- die Vielzahl an Prozessschritten und Prozesskettenelementen,
- die Vielfalt an Prozessarten,
- die Vieldeutigkeit von Beziehungen, welche insbesondere aus den indirekten und mehrfachen Ursachen-Wirkzusammenhängen resultieren sowie
- die Veränderlichkeit von Eigenschaften aufgrund von Zeitabhängigkeiten.




Abbildung 9: Ausprägungsformen von Ursachen-Wirkzusammenhängen

(aus WESTERMEIER 2016, S. 14).

Zur weiteren Abgrenzung kann auf die von ULRICH & PROBST beschriebenen Klassifikationen in einfache, komplizierte, relativ komplexe und äußerst komplexe Systeme zurückgegriffen werden (vgl. Abbildung 10) (ULRICH & PROBST 1995). Demnach zeichnen sich einfache Systeme durch wenige Elemente (hier: Prozesskettenelemente) und Beziehungen (hier: Ursachen-Wirkzusammenhänge) aus. Das Verhalten der Elemente ist bei einfachen Systemen deterministisch. Steigt die Anzahl an Elementen und Beziehungen, so spricht man von einem komplizierten System. Komplexe Systeme sind hingegen durch eine hohe Eigendynamik charakterisiert, wie bspw. eine Verhaltensvarietät in der Zeit. Bei geringer Anzahl von Elementen und Beziehungen spricht man von einem relativ komplexen System. Äußerst komplexe Systeme zeichnen sich dadurch aus, dass neben der hohen Eigendynamik insbesondere eine hohe Anzahl von Elementen und Beziehungen vorliegt. Für eine detaillierte Beschreibung sei auf die Arbeiten von ULRICH & PROBST, ERK sowie WEISER verwiesen (PROBST & GOMEZ 1991, ERK 2016, WEISER 2018).

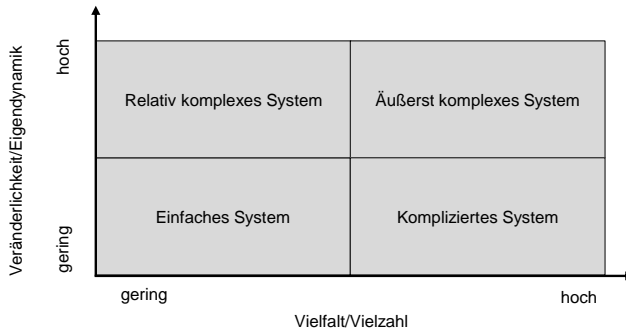


Abbildung 10: Abgrenzung von komplizierten und komplexen Systemen (ULRICH & PROBST 1995).

#### 2.2.4 Kausalitäten in Prozessketten

Unter einer Kausalität kann im Allgemeinen eine aus naturgesetzlichen Zusammenhängen resultierende Beziehung zwischen Ursache und Wirkung verstanden werden (HÜGENS 2009, S. 121; WESTERMEIER 2016, S. 10). Ursachen und Wirkungen können im Kontext einer verfahrenstechnischen oder fertigungstechnischen Prozesskette zwischen Prozesskettenelementen, also Eingangs- und Zwischenproduktmerkmalen sowie finalen Produkteigenschaften, vorliegen (vgl. Abbildung 7 und Abbildung 9). Fehlt zwischen zwei Prozesskettenelementen trotz identifizierter Korrelation ein naturgesetzlicher Zusammenhang, so wird von einer *Scheinkorrelation* bzw. *Pseudokorrelation* gesprochen (BARTELS 2009; WESTERMEIER 2016, S. 10).

Um eine Kausalität im industriellen Kontext zu beurteilen, kann bspw. auf eine Visualisierung von Daten und deren Interpretation durch einen Prozessexperten zurückgegriffen werden. Dass eine Beurteilung rein deskriptiver Zahlen, wie bspw. eines Korrelationskoeffizienten nicht hinreichend ist, kann in Abbildung 11 mithilfe eines exemplarischen Datensatzes nach ANSCOMBE verdeutlicht werden (ANSCOMBE 1981, S. 17-21).

Demnach zeichnen sich die Datensätze aus Abbildung 11 a) – d) durch dasselbe arithmetische Mittel von 9,0 (bezogen auf die x-Variablen) bzw. 7,5 (bezogen auf die y-Variablen) sowie den identischen Korrelationskoeffizienten nach Bravais-Pearson<sup>6</sup> von 0,8 aus. Erst durch die

<sup>6</sup> Maß für den Grad eines linearen Zusammenhanges abgeleitet aus einer Regressionsgerade (vgl. LINS 2013, S. 180-181).

Visualisierung der Daten wird deutlich, dass eine Beurteilung allein auf Grundlage der Datenpunkte bzw. der deskriptiven Zahlen nicht hinreichend ist, da die zugrundeliegenden graphischen Strukturen vollkommen unterschiedlich sein können. (DORMANN 2017, S. 156; WOLF & BEST 2010, S. 109)

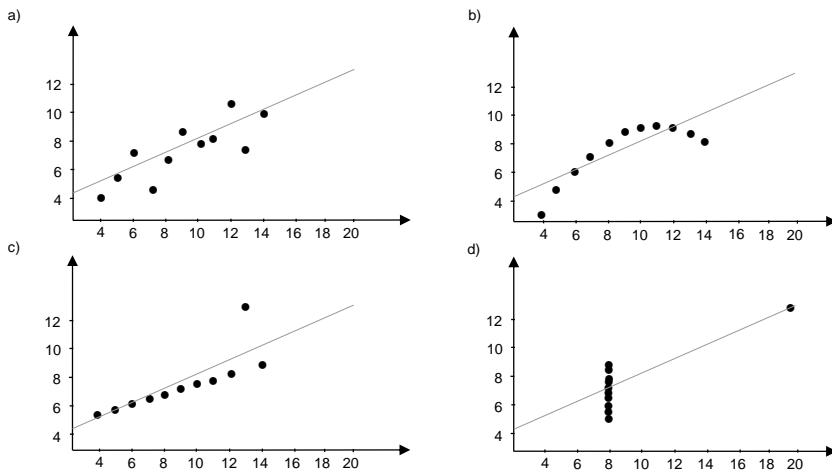


Abbildung 11: Exemplarischer Datensatz nach ANSCOMBE 1981, S. 17, um die Bedeutung einer Visualisierung herauszustellen.

Wird im Kontext dieser Arbeit von einem qualitätsrelevanten Ursachen-Wirkzusammenhang gesprochen, so wird darunter der kausale Zusammenhang zwischen Prozesskettenelementen, also zwischen Eingangs- und Zwischenproduktmerkmalen oder finalen Produkteigenschaften, verstanden (vgl. Abbildung 9).

### 2.2.5 Methoden des Qualitätsmanagements

Der vorliegende Abschnitt dient einer Einführung in etablierte Methoden und Werkzeuge des Qualitätsmanagements. Abbildung 12 zeigt dabei die Zuordnung anhand der Phasen des Produktentstehungsprozesses.



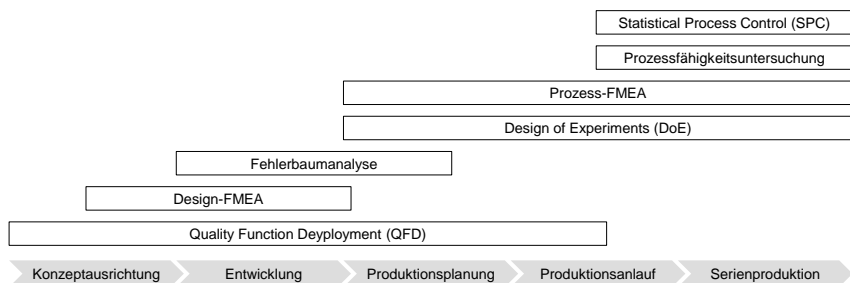


Abbildung 12: Einsatz von Qualitätsmanagementmethoden, zugeordnet anhand der Phasen eines Produktentstehungsprozesses (aus BRÜGGEMANN & BREMER 2015, S. 13).

**Quality Function Deployment (QFD)** stellt eine Methode zur systematischen Qualitätsplanung auf Basis von Kundenanforderungen dar. Sie soll es ermöglichen, Kundenanforderungen in qualitätsbeeinflussende Eigenschaften von Produkten und Prozessen umzuwandeln (LINß 2013, 194). Wie von WENGLER aufgezeigt, lässt sich die Methode auch für eine systematische Darstellung von Systemelementen anwenden (WENGLER 1996). Für eine detaillierte Beschreibung zur Vorgehensweise sei auf LINß 2013, S. 194 ff. verwiesen.

Die Fehlermöglichkeits- und Einflussanalyse (FMEA) repräsentiert eine Möglichkeit zur Risiko- bzw. Ausfallanalyse (KÖHLER 2008, S. 182). Sie kann in der frühen Phase eines Produktentstehungsprozesses zur Auslegung der Konstruktion (**Design-FMEA**) oder der Prozesse (**Prozess-FMEA**) angewendet werden. Sie ist im Kontext der vorliegenden Arbeit von hoher Relevanz, da sie einen systematischen Ansatz zur Wissensakquisition über Prozesskettenelemente als auch eine Methode zur Fehler-Ursachen-Analyse bietet. Eine detaillierte Beschreibung der Methode erfolgt deshalb separat in Abschnitt 2.2.6.

Die **Fehlerbaumanalyse** (engl. Fault Tree Analysis, kurz FTA) stellt eine weitere Methode zur Risiko- bzw. Ausfallanalyse dar. Wie Abbildung 13 zu entnehmen ist, wird dabei eine Baumstruktur eines Gesamtsystems mithilfe seiner Teilsysteme aufgebaut, wobei eine Verknüpfung der Teilsysteme anhand boolescher Operatoren erfolgt. Im Sinne eines Top-Down-Ansatzes findet ausgehend von einem identifizierten Fehler ein rückwärtsgerichteter Analysevorgang statt (LINß 2013, S. 527-531). Die Fehlerbaumanalyse wird insbesondere zur Beurteilung von Produkten verwendet, weshalb sich die Methode vorwiegend in der Entwicklungsphase findet. Das der Fehlerbaumanalyse zugrundeliegende Vorgehen lässt sich wie folgt zusammenfassen (BRÜGGEMANN & BREMER 2015, S. 38):

- Identifikation von Teilsystemen und Fehlerursachen
- Ermittlung der Ausfallhäufigkeiten von Ursachen

- Aufstellung des Fehlerbaumes (inkl. der booleschen Verknüpfungen)
- Auswertung des Fehlerbaumes

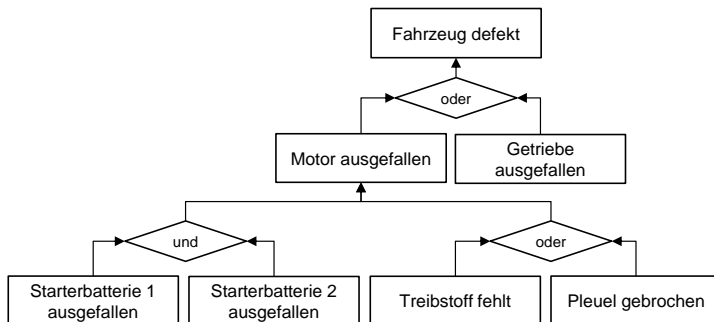


Abbildung 13: Beispiel für einen Fehlerbaum (in Anlehnung an BRÜGGEMANN & BREMER 2015, S. 41).

Das **Design of Experiments** (deutsch: Statistische Versuchsplanung) lässt sich den statistischen Verfahren des Qualitätsmanagements zuordnen. Es repräsentiert eine Methode zur systematischen Produkt- und Prozessentwicklung. Das Ziel der Methode liegt darin, Ursachen-Wirkzusammenhänge zwischen Parametern mit minimalem Aufwand zu identifizieren und die Parameter hinsichtlich eines definierten Zieles auf einen optimalen Wert einzustellen. Im Kontext einer Prozesskette sind die Parameter als Eingangs- und Zwischenproduktmerkmale sowie finale Produkteigenschaften zu verstehen. Der Nutzen eines Design of Experiments soll mithilfe des Beispiels in Abbildung 14 verdeutlicht werden. Dabei ist zu erkennen, dass in traditionellen Versuchsplänen zur Identifikation von Ursachen-Wirkzusammenhängen sämtliche Kombinationen von Faktorstufen<sup>7</sup> betrachtet werden. Der Aufwand von Versuchen steigt mit der Anzahl der zu betrachtenden Faktoren exponentiell an (MOLLENHAUER 2007, S. 163). Mithilfe des Design of Experiments lassen sich Versuchspläne so konstruieren, dass die Anzahl an Versuchen durch Vorgabe von Genauigkeiten und Berücksichtigung von Restriktionen reduziert werden kann (vgl. BRÜGGEMANN & BREMER 2015, S. 72 ff. und KLEPPMANN 2011).

---

<sup>7</sup> Ein Faktor ist als Einflussgröße zu betrachten, welcher reproduzierbar eingestellt werden kann. Im Versuchsplan wird ein Faktor auf verschiedene Werte, die sogenannten Faktorstufen eingestellt (KLEPPMANN 2011, S. 33).

In diesem Zusammenhang sei auch auf den Unterschied zwischen labororientierten und feldorientierten Untersuchungen hingewiesen. Bei labororientierten Untersuchungen werden Ursachen-Wirkzusammenhänge durch strenge Konstanthaltung von Versuchsbedingungen und gezielte Veränderung der Eingangsgrößen analysiert (Ceteris-Paribus-Prinzip). Das Design of Experiments lässt sich einem solchen Ansatz zuordnen. In feldorientierten Untersuchungen hingegen werden Daten aus einem realen System ohne gezielte Veränderung bzw. Konstanthaltung von Eingangsgrößen analysiert (SCHÄFER 2003, S. 10). Hierzu zählen Methoden des Data-Minings, welche in Abschnitt 2.2.9 diskutiert werden.

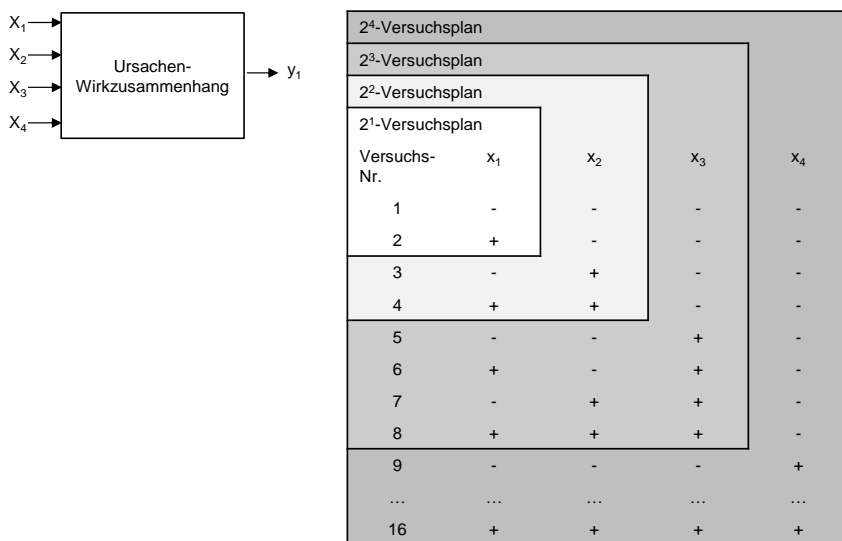


Abbildung 14: Vollständig faktorieller Versuchsplan für vier Eingangsgrößen

(aus KLEPPMANN 2011, S. 108).

Die Regelung eines Prozesses mithilfe statistischer Methoden wird als **statistische Prozesslenkung** (engl. Statistical Process Control, kurz SPC) bezeichnet (BRÜGGEMANN & BREMER 2015, S. 113). Die statistische Prozesslenkung findet sich in bereits laufenden Produktionen und zielt darauf ab, qualitätsrelevante Prozesskettenelemente zu überwachen und zu bewerten. Sie baut dabei auf einer systematischen Stichprobenprüfung auf (LINß 2013, S. 306). Ein relevantes Werkzeug der statistischen Prozesslenkung stellt die Qualitätsregelkarte dar. Wie Abbildung 15 zu entnehmen ist, werden hierbei bspw. Einzelwerte, Mittelwerte oder Standardabweichungen von Prozesskettenelementen auf einer Ordinate eingetragen.




Abbildung 15: Aufbau einer Qualitätsregelkarte (BRÜGGEMANN & BREMER 2015, S. 116).

Eine Beurteilung erfolgt unter Berücksichtigung des zeitlichen Verlaufes der Kenngrößen durch einen Vergleich mit Grenzen. Die Grenzen werden dabei bezeichnet als (LINß 2013, S. 307):

- obere bzw. untere Warngrenze (OWG bzw. UWG) und
- obere bzw. untere Eingriffsgrenze (OEG bzw. UEG).

Liegt der Wert einer Kenngröße zwischen der Eingriffs- und Warngrenze, so kann der Prozess weiter fortgeführt werden. Außerhalb der Warngrenze ist der Prozess mit erhöhter Aufmerksamkeit zu verfolgen und zu regeln. Für die Berechnung der unterschiedlichen Eingriffsgrenzen sei auf LINß verwiesen. (LINß 2013, S. 308)

Prozessfähigkeitsindizes stellen weitere Kenngröße dar, die in einer Qualitätsregelkarte überwacht werden können. Sie resultieren aus einer **Prozessfähigkeitsuntersuchung** (vgl. WOHLRABE 2009 und LINß 2013, s. 333-332). Die Prozessfähigkeitsuntersuchung stellt einen Eignungsnachweis für Maschinen und Prozesse dar. Dabei erfolgt ein Vergleich zwischen geforderten Toleranzen und den erbrachten Eigenschaften von Prozesskettenelementen. Prozessfähigkeitsuntersuchungen repräsentieren eine etablierte Möglichkeit, um statistisch nachzuweisen, dass ein Fertigungsprozess die Produkte mit geforderter Qualität herstellen kann (ESCHEY 2013, S. 23). Eine detaillierte Beschreibung unterschiedlicher Formen von Prozessfähigkeitsindizes erfolgt in Abschnitt 2.2.8.

### 2.2.6 Fehlermöglichkeits- und -einflussanalyse (FMEA)

Die Fehlermöglichkeits- und -einflussanalyse (FMEA) ist definiert als eine formalisierte, analytische Methode zur Untersuchung möglicher Fehlerarten sowie deren Fehlerursachen und Fehlerfolgen (GEIGER & KOTTE 2008, S. 128). Die FMEA basiert dabei auf einer Wissensakquisition von Experten. Je nach betrachteter Phase des Produktentwicklungsprozesses erfolgt eine Differenzierung in Design- oder Prozess-FMEA. Während bei einer Design-FMEA die produktgerechte Gestaltung und Auslegung einzelner Bauteile sichergestellt werden soll, liegt der Fokus der Prozess-FMEA in der fehlerfreien Herstellung eines Produktes (BRÜGGEMANN & BREMER 2015, S. 45).

Der erste Schritt der FMEA sieht die Erstellung einer Systemstruktur vor. Hierbei werden mögliche Fehlerbilder gesammelt und miteinander in Beziehung gesetzt. Das Ergebnis des Prozessschrittes ist ein Funktionsbaum, welcher ein Fehlernetzwerk aus Fehlern, Fehlerfolgen und Fehlerursachen darstellt. Um den Fehlern in geeigneter Reihenfolge zielorientiert entgegenwirken zu können, erfolgt eine Risikobewertung mithilfe der sogenannten Risikoprioritätszahl *RPZ*. Diese setzt sich nach Formel (2.1) aus der Multiplikation dreier Kennzahlen *W*, *E* und *B* zusammen. Die Kennzahlen stellen ganzzahlige Bewertungspunkte im Bereich 1 bis 10 dar und werden im Rahmen einer Expertenbefragung ermittelt (BRÜGGEMANN & BREMER 2015, S. 49).

$$RPZ = W \cdot E \cdot B \quad (2.1)$$

Im Detail beschreibt (LINß 2013, S. 589-590):

- *W* die Auftretenswahrscheinlichkeit eines Fehlers, mit *W* = 1 als unwahrscheinlich und *W* = 10 als nahezu sicher, dass ein Fehler auftritt.
- *E* die Entdeckungswahrscheinlichkeit eines Fehlers, mit *E* = 1 als nahezu sicher und *E* = 10 als unwahrscheinlich, dass ein Fehler entdeckt wird.
- *B* die Bedeutung der Fehlerfolge, mit *B* = 1 als unwahrscheinlich, dass ein Fehler wahrnehmbare Auswirkungen haben könnte und *B* = 10 als nahezu sicher, dass der Fehler die Sicherheit und/oder die Einhaltung gesetzlicher Vorschriften beeinträchtigt.

Aus den Beschreibungen lässt sich ableiten, dass mithilfe der *RPZ* die Rangfolge von Risiken ermittelt und Abstellmaßnahmen priorisiert werden können. Die Durchführung einer FMEA

kann händisch mithilfe von Formblättern oder unterstützt durch Software erfolgen (vgl. WERDICH 2012, S. 114). Abbildung 16 stellt exemplarisch eine Vorlage eines FMEA-Formblattes dar.

										FMEA
										Seite
Typ/ Modell/ Fertigung/ Charge				Sach-Nr.:		Verantw.:			Abt.:	
				Änderungsstand		Firma:			Datum:	
System-Nr. / Systemelement:				Sach-Nr.:		Verantw.:			Abt.:	
Funktion/ Aufgabe:				Änderungsstand		Firma:			Datum:	
Mögliche Fehlerfolgen	B	Mögliche Fehler	Mögliche Fehlerursachen	Vermeidungsmaßnahmen	A	Entdeckungsmaßnahmen	E	RPZ	V/T	

B = Bewertungszahl für die Bedeutung

RPZ = Risikoprioritätszahl.  $RPZ = B \cdot A \cdot E$

A = Bewertungszahl für die Auftretenswahrscheinlichkeit

V = Verantwortlichkeit

E = Bewertungszahl für die Entdeckungswahrscheinlichkeit

T = Termin für die Erledigung

Abbildung 16: FMEA-Formblatt nach VDA Band 4.

### 2.2.7 Qualitätskennzahlen

Kennzahlen werden nach REICHMANN definiert als „[...] jene Zahlen [...], die quantitativ erfassbare Sachverhalte in konzentrierter Form [...]“ abbilden (REICHMANN 1997, S. 19). Nach MÜLLER ermöglichen sie es zudem, „[...] Aussagen über die Qualität der Aufgabenerfüllung“ zu treffen (MÜLLER 2010, S. 12). Sie repräsentieren demnach ein essenzielles Steuerinstrument eines Qualitätsmanagements, da sie den Zielerreichungsgrad abbilden können (MÜLLER 2010, S. 11; VMDA 66412-1). Wichtige Elemente einer Qualitätskennzahl sind (REICHMANN ET AL. 2006, S. 19 ff.):

- Informationscharakter als Grundlage der Urteilsbildung,
- die Quantifizierbarkeit und
- die spezifische Form der Informationen, um bspw. komplexe Sachverhalte simplifiziert abzubilden.

Leistungskennzahlen (im Englischen Key Performance Indicators, kurz KPI) besitzen einen besonderen Stellenwert, da „[...] anhand derer der Fortschritt oder der Erfüllungsgrad hinsichtlich wichtiger Zielsetzungen oder kritischer Erfolgsfaktoren innerhalb einer Organisation gemessen werden kann“ (VMDA 66412-1). Sie zeichnen sich durch einen höheren Aggregierungsgrad aus und ermöglichen es dadurch, eine Verbindung zwischen den operativen und strategischen Zielen eines Unternehmens herzustellen (ISO 22400-1).

Im Kontext verfahrenstechnischer und fertigungstechnischer Prozessketten lassen sich unterschiedliche Kennzahlen identifizieren, um Eingangs- und Zwischenproduktmerkmale sowie finale Produkteigenschaften zu bewerten. Eine Zusammenfassung von Kennzahlen ist dem Einheitsblatt VMDA 66412-1 zu entnehmen. Etablierte Kennzahlen wie bspw. die Qualitätsrate, die Ausschussquote oder die DPMO (Defects per Million Opportunities, auf Deutsch: Fehler pro Millionen Möglichkeiten) sind zudem im Anhang 8.1, Tabelle 8-1 beschrieben.

### 2.2.8 Prozessfähigkeitsuntersuchungen

Das Ziel einer Prozessfähigkeitsuntersuchung liegt darin, einen Eignungsnachweis für Maschinen und Prozesse zu erbringen (LINß 2013, S. 446). Prozessfähigkeitsindizes stellen die Kennzahl einer solchen Fähigkeitsuntersuchung dar. Sie zeigen auf, dass ein Fertigungsprozess die Produkte mit geforderter Qualität herstellen kann (ESCHEY 2013, S. 23). Dabei wird die Häufigkeitsverteilung einer messbaren Eigenschaft mit seiner vorgegebenen Toleranz verglichen. Dies ermöglicht eine für den Anwender leicht nachvollziehbare Beurteilung der Qualität. Zudem liegt ein direkter Zusammenhang zwischen der Prozessfähigkeit und dem Produktionsausschuss vor, was eine Beurteilung des Qualitätsniveaus auch aus wirtschaftlicher Perspektive ermöglicht. Folglich können Prozessfähigkeitsindizes als relevante KPI betrachtet werden. (BRÜGGEMANN & BREMER 2015, S. 107 ff.).

Im Allgemeinen wird zwischen univariaten und multivariaten Prozessfähigkeitsindizes unterschieden. Univariate Prozessfähigkeitsindizes dienen der isolierten Betrachtung einzelner Eigenschaften von Prozesskettenelementen. Auf Basis von multivariaten Prozessfähigkeitsuntersuchungen können gleichzeitig mehrere Eigenschaften bewertet werden (DE-FELIPE 2017).

Während der *Prozessfähigkeitsindex*  $C_p$  nach Formel (2.2) das alleinige Verhältnis aus Spezifikationen (OSG und USG)<sup>8</sup> und Streubereich  $\sigma$  beschreibt, kann gemäß Formel (2.3) mithilfe

---

<sup>8</sup> OSG für obere Spezifikationsgrenze und USG für untere Spezifikationsgrenze

des *kritischen Prozessfähigkeitsindex*  $C_{pk}$  zusätzlich die Lage des Mittelwertes  $\mu$  mitberücksichtigt werden (BRÜGGEMANN & BREMER 2015, S. 107 ff.).

$$C_p = \frac{\text{Spezifikationen}}{\text{Prozessstreuung}} = \frac{OSG - USG}{6 \sigma} \quad (2.2)$$

$$C_{pk} = \left[ \frac{\mu - USG}{3\sigma}, \frac{OSG - \mu}{3\sigma} \right] \quad (2.3)$$

Aus dem totalen Qualitätsdenken von TAGUCHI ET AL. lässt sich in Anlehnung an Formel (2.2) und Formel (2.3) der totale *Prozessfähigkeitsindex*  $C_{pm}$  ableiten (TAGUCHI ET AL. 2005). Während der *Prozessfähigkeitsindex*  $C_p$  bzw. der *kritische Prozessfähigkeitsindex*  $C_{pk}$  den Qualitätsverlust erst bei Überschreitung der spezifizierten Toleranzen berücksichtigt, beruht der *totale Prozessfähigkeitsindex*  $C_{pm}$  auf der Annahme, dass ein Qualitätsverlust bereits bei einer Abweichung vom Zielwert vorliegt. Der Qualitätsverlust erhöht sich dabei parabolisch, unabhängig davon, ob die Spezifikationen eingehalten werden oder nicht (vgl. Abbildung 17).

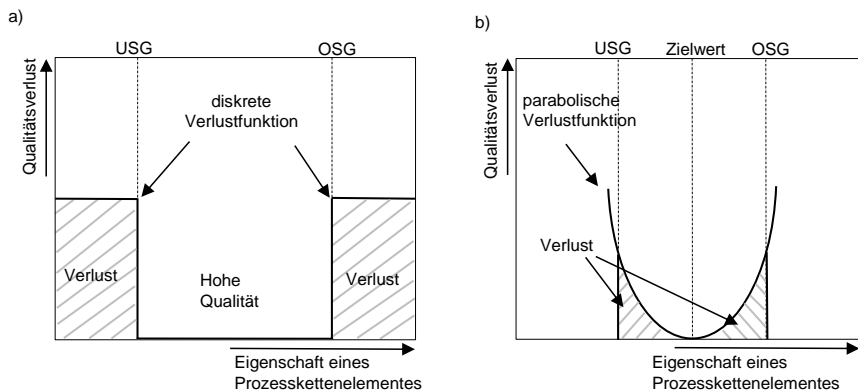


Abbildung 17: a) diskretes Qualitätsverständnis zur Berechnung der Prozessfähigkeitsindizes  $C_p$  bzw.  $C_{pk}$ ; b) kontinuierliches Qualitätsverständnis zur Berechnung der Prozessfähigkeitsindizes  $C_{pm}$  bzw.  $C_{pmk}$ .

(nach LINB 2013, S. 447).

Der *totale Prozessfähigkeitsindex*  $C_{pm}$  errechnet sich gemäß Formel (2.4). Darüber hinaus lässt sich analog zur Vorgehensweise des *kritischen Prozessfähigkeitsindex*  $C_{pk}$  mithilfe des



totalen kritischen Prozessfähigkeitsindex  $C_{pmk}$  (vgl. Formel (2.5)) auch die Lage des Mittelwertes  $\mu$  berücksichtigen (vgl. LINß 2013, S. 446-450; CHAN ET AL. 1988, S. 162-175).

$$C_{pm} = \frac{OSG - USG}{6 \sqrt{\sigma^2 + (\mu - T)^2}} \quad (2.4)$$

$$C_{pmk} = \min \left[ \frac{OSG - \mu}{3[\sigma^2 + (\mu - T)^2]^{1/2}}, \frac{\mu - USG}{3[\sigma^2 + (\mu - T)^2]^{1/2}} \right] \quad (2.5)$$

Univariate Prozessfähigkeitsindizes werden ausschließlich bei einer isolierten Betrachtung einzelner Eigenschaften von Prozesskettenelementen hinzugezogen. Liegen allerdings Ursachen-Wirkzusammenhänge zwischen mehreren Eigenschaften von Prozesskettenelementen vor, so kann auf multivariate Prozessfähigkeitsuntersuchungen zurückgegriffen werden, um eine aggregierte Bewertung der Eigenschaften zu ermöglichen (BRACKE 2016, S. 31). Ein in der Industrie bewährter Ansatz zur Berechnung des *multivariaten Prozessfähigkeitsindex*  $MC_{pk}$  wurde von DE-FELIPE & BENEDITO entwickelt und ist Formel (2.6) zu entnehmen (DE-FELIPE & BENEDITO 2017B; DE-FELIPE & BENEDITO 2017A).

$$MC_{pk,i} = -\frac{1}{3}\phi^{-1}\left(1 - \int_{R_{crit_S}} \frac{1}{|\Sigma|2^n\pi^n} e^{-\frac{1}{2}(Y-\mu)^T\Sigma^{-1}(Y-\mu)} dY\right) \quad (2.6)$$

Der *multivariate Prozessfähigkeitsindex*  $MC_{pk}$  berechnet sich für jede Eigenschaft eines Prozesskettenelementes  $Y_i$  auf Basis der Verteilungsfunktion der Normalverteilung  $\phi$ , der Varianz-Kovarianz-Matrix  $\Sigma$ , in welcher die jeweiligen Korrelationen der Eigenschaften von Prozesskettenelementen enthalten sind, und des Zielwertes  $T$ . Dabei stellt  $R_{crit_S}$  die Vereinigung der Teilmengen kritischer Prozessregionen für jede Produkteigenschaft  $i \in \{1, \dots, n\}$  dar. Für eine Herleitung und detaillierte Beschreibung des multivariaten Prozessfähigkeitsindex  $MC_{pk}$  sei auf DE-FELIPE & BENEDITO 2017B sowie DE-FELIPE & BENEDITO 2017A verwiesen.

Die Charakteristiken der diskutierten Prozessfähigkeitsindizes sind im Flussdiagramm in Abbildung 18 dargestellt. Hier lässt sich erkennen, dass eine Differenzierung in univariate und multivariate Prozessfähigkeitsindizes erfolgt. Darüber hinaus ist die Art des Qualitätsverständnisses entscheidend, da hierüber definiert wird, ob auf Prozessfähigkeitsindizes mit diskreter oder parabolischer Verlustfunktion zurückgegriffen wird.

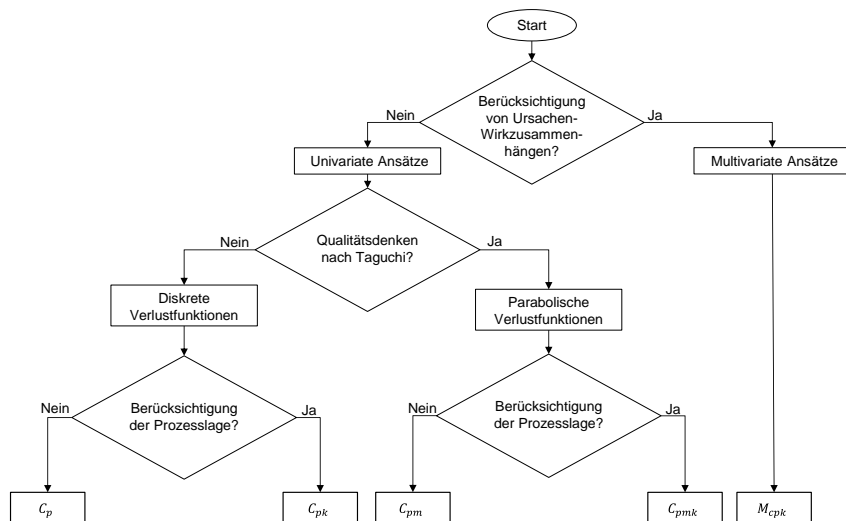


Abbildung 18: Flussdiagramm zur Bestimmung eines anwendungsgerechten Prozessfähigkeitsindizes.

## 2.2.9 Datenanalyse

Die Digitalisierung in verfahrenstechnischen oder fertigungstechnischen Prozessketten führt zu einer Verfügbarkeit großer Datenmengen und zu einem erhöhten Bedarf an Datenanalyse (THIEDE ET AL. 2019, S. 4). In diesem Zusammenhang beschreibt die Wissensentdeckung in Datenbanken (engl. Knowledge Discovery in Databases, kurz KDD) nach FAYYAD ET AL. einen „[...] nicht-trivialen Prozess zur Identifizierung valider, neuer, potentiell nützlicher und schließlich verständlicher Muster in Daten“ (FAYYAD ET AL. 1996). Der Begriff *nicht-trivial* fordert dabei, dass Algorithmen zur Anwendung kommen, welche sich von einfachen statistischen Auswertungen unterscheiden (ALPAR & NIEDEREICHHOLZ 2000, S. 4).

*Data-Mining* wird in diesem Kontext als ein Prozessabschnitt der *KDD* verstanden. Es wird definiert als „[...] die Anwendung spezifischer Algorithmen zur Extraktion von Mustern aus Daten“ (FAYYAD ET AL. 1996). Allerdings etablierte es sich, den Begriff des *Data-Minings* oder der *Data Analytics* für den gesamten Prozess der *KDD* zu verwenden (ALPAR & NIEDEREICHHOLZ 2000, S. 4; GHAVAMI 2019). In der vorliegenden Arbeit soll der Praxis gefolgt werden. Somit wird der Begriff *Data-Mining* bzw. *Data-Analytics* in dieser Arbeit als Synonym zu *KDD* verwendet.

Für die Umsetzung des Data-Minings haben sich unterschiedliche Prozessmodelle etabliert. Das Prozessmodell nach FAYYAD ET AL. ist Abbildung 19 zu entnehmen und sieht insgesamt fünf Phasen vor, um Daten in Wissen zu überführen.

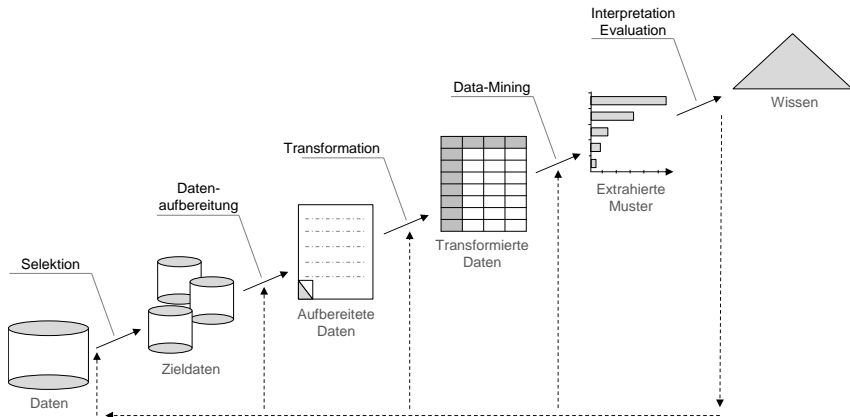


Abbildung 19: Schritte des Data-Mining-Prozessmodells nach FAYYAD ET AL. 1996, S. 41.

Ausgehend von einem Datenbestand erfolgt zunächst die Selektion von Zieldaten. Diese werden im Schritt der Datenaufbereitung hinsichtlich möglicher Fehler und Ausreißer analysiert und gereinigt. Während der Transformation werden die aufbereiteten Daten in ein passendes Analyseformat umgewandelt. Es folgt die Anwendung des eigentlichen Data-Mining, in welchem mithilfe ausgewählter Methoden Muster extrahiert werden, die durch Experten zu interpretieren und evaluieren sind, sodass Wissen generiert werden kann. (FAYYAD ET AL. 1996; ALPAR & NIEDEREICHHOLZ 2000; FREITAG ET AL. 2015).

Ein in der Industrie etabliertes Prozessmodell zur Datenanalyse stellt der Cross Industry Standard Process for Data Mining (kurz CRISP-DM) dar (SHEARER 2000). Dieser kann als Weiterentwicklung des Prozessmodells aus Abbildung 19 angesehen werden. Wie Abbildung 20 zu entnehmen ist, besteht CRISP-DM aus insgesamt 6 Prozessschritten. Im ersten Prozessschritt sind die Ziele und Anforderungen an ein Data-Mining-Projekt festzulegen. Mithilfe des darauffolgenden Datenverständnisses soll eine Beurteilung der Datenqualität ermöglicht werden. Es folgt der Prozessschritt der Datenaufbereitung, welcher alle Aktivitäten zur Auswahl, Bereinigung und Transformation der Daten beinhaltet. Der Modellierungsprozess umfasst die Verwendung von Methoden, um für die vorab definierten Ziele geeignete Modelle zu bilden. Nach

einer erfolgreichen Evaluation kann das Modell in der Praxis eingesetzt werden. Wie zu erkennen ist, werden im CRISP-DM insbesondere auch die für eine zielorientierte Datenanalyse relevanten Iterationen zwischen den einzelnen Prozessschritten hervorgehoben. (ALPAR & NIEDEREICHOLZ 2000; FREITAG ET AL. 2015)

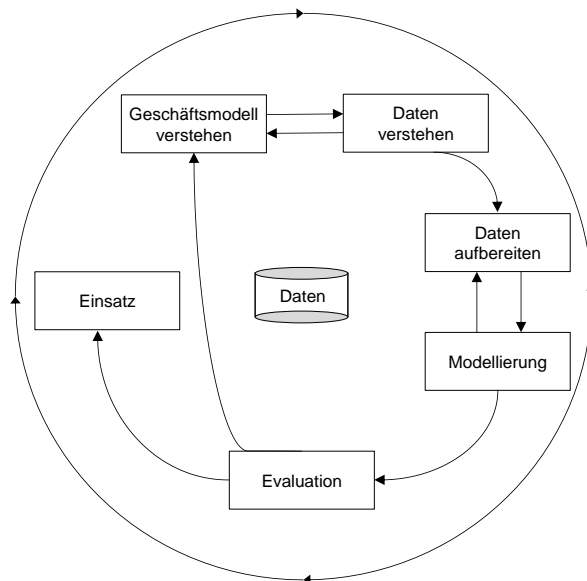


Abbildung 20: Schritte des Data-Mining-Prozessmodells CRISP-DM (SHEARER 2000).

Die Auswahl geeigneter Methoden für den Prozessschritt der Modellierung hängt stark von den jeweiligen Zielen eines Data-Mining-Projektes ab. Nach ALPAR & NIEDEREICHOLZ können die Ziele einer Datenanalyse differenziert werden in Klassifikation, Segmentierung, Prognose, Abhängigkeitsanalyse und Abweichungsanalyse (ALPAR & NIEDEREICHOLZ 2000, S. 13). Bei der *Klassifikation* wird versucht, betrachtete Objekte einer vorher definierten Klasse zuzuordnen. Hingegen erfolgt bei der *Segmentierung* eine Zuordnung von Objekten anhand vorher nicht bekannter Klassen. Die Prognose dient einer Vorhersage von Eigenschaften von Objekten. Mithilfe der Abhängigkeitsanalyse sollen Ursachen-Wirkzusammenhänge zwischen Objekten identifiziert werden. Die Abweichungsanalyse dient dazu, Objekte zu ermitteln, die von einem geforderten Wert abweichen. Von der Vielzahl an Methoden, die zur Lösung der beschriebenen Ziele beitragen können, sind einige exemplarisch in Abbildung 21 aufgelistet. Für

eine detaillierte Beschreibung der Methoden sei auf PETERSOHN 2009 und ALPAR & NIEDEREICHHOLZ 2000 verwiesen.

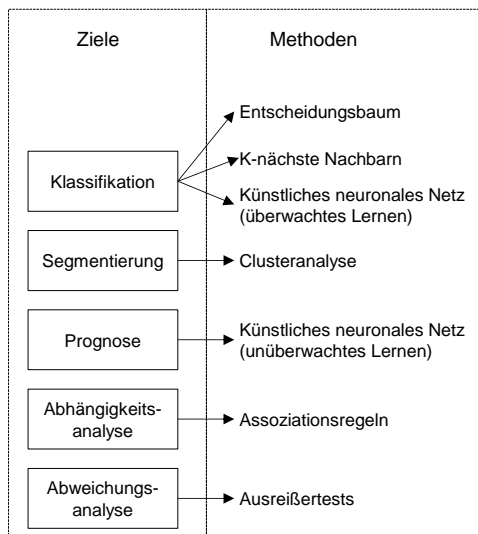


Abbildung 21: Zuordnung von Data-Mining-Zielen und Data-Mining-Methoden (ALPAR & NIEDEREICHHOLZ 2000, S. 13)

Im Weiteren können Datenanalysemethoden auch nach Komplexitätsgrad und erbrachtem Mehrwert differenziert werden. Wie in Abbildung 22 dargestellt, kann eine Aufteilung in *deskriptive*, *diagnostische*, *prädiktive* sowie *präskriptive* Verfahren erfolgen, wobei jedem der genannten Verfahren eine analytische Fragestellung zugeordnet werden kann. *Deskriptive Analyseverfahren* adressieren die Fragestellung „*Was ist passiert?*“ und beziehen sich damit meist auf manuelle und kennzahlenorientierte Datenanalysen, um vergangenheitsorientierte Geschehnisse nachzuvollziehen. Ein Beispiel im Kontext des Qualitätsmanagements stellt ein ermittelter Produktionsausschuss dar. Mithilfe *diagnostischer Analyseverfahren* lässt sich die Fragestellung beantworten, warum etwas passiert ist. Auf Basis identifizierter Ursachen-Wirkzusammenhänge kann bspw. auf den Grund eines Produktionsfehlers geschlossen werden. *Prädiktive Analyseverfahren* verfolgen das Ziel, zukünftige Ereignisse mithilfe bereits identifizierter Ursachen-Wirkzusammenhänge vorherzusagen. Im Kontext des Qualitätsmanagements verfahrenstechnischer oder fertigungstechnischer Prozessketten ermöglicht ein solches

Analyseverfahren nicht nur die Ursachen, sondern auch die Folgen eines aufgetretenen Fehlers zu bewerten. *Präskriptive Analyseverfahren* verfolgen das Ziel, eine Handlungsempfehlung auf Basis definierter Analyseziele bereitzustellen. Sie weisen den größten Mehrwert auf, da sie den Nutzer bei Optimierungsproblemen vollständig unterstützen. Gleichzeitig besitzen sie auch den größten Komplexitätsgrad aller genannten Analyseverfahren. Ein Beispiel stellt die Empfehlung optimaler Produktionsparameter dar, um einen Ausschuss zu reduzieren. (GRÖGER 2015, S. 48-49; APPELFELLER & FELDMANN 2018, S. 89-91; OBDENBUSCH 2018, S. 47)

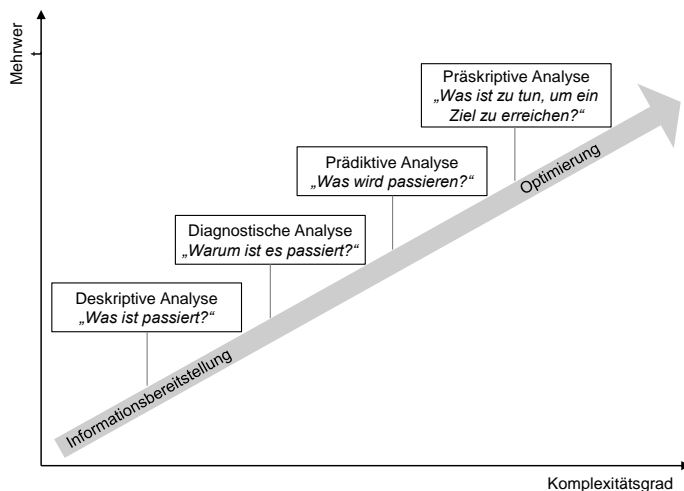


Abbildung 22: Analytisches Aufstiegsmodell zur Zuordnung deskriptiver, diagnostischer, prädiktiver sowie präskriptiver Verfahren der Datenanalyse (WIRAEUS ET AL. 2019, S. 171; GRÖGER 2015, S. 48).

### 2.2.10 Bayes-Theorem und Bayessche Netzwerke

Um Beziehungen zwischen Objekten wie bspw. Prozesskettenelementen zu beschreiben, können neben den Methoden der Datenanalyse auch Ansätze der Bayesschen Statistik verwendet werden. Das Bayes-Theorem repräsentiert in diesem Kontext einen fundamentalen Satz aus der Wahrscheinlichkeitstheorie, um bedingte Wahrscheinlichkeiten von Ereignissen

zu berechnen. Im Falle zweier Ereignisse  $A_i$  und  $B_j$  lässt sich mithilfe des Bayes-Theorems die bedingte Wahrscheinlichkeit von  $A_i$  gegeben<sup>9</sup>  $B_j$  errechnen als (HESSE 2003, S. 49-50):

$$P(A_i|B_j) = \frac{P(B_j|A_i) P(A_i)}{P(B_j)} \quad (2.7)$$

mit

- $P(B_j|A_i)$  als bedingte Wahrscheinlichkeit des Auftretens von  $B_j$ , gegeben  $A_i$ ,
- $P(A_i|B_j)$  als bedingte Wahrscheinlichkeit des Auftretens von  $A_i$ , gegeben  $B_j$ ,
- $P(B_j)$  als A-priori-Wahrscheinlichkeit von Ereignis  $B_j$  und
- $P(A_i)$  als A-priori-Wahrscheinlichkeit von Ereignis  $A_i$ .

Für die zwei Ereignisse  $A$  und  $B$  lässt sich mithilfe des Bayes-Theorems die Frage beantworten: „Wie hoch ist die Wahrscheinlichkeit, dass  $A$  die Ursache ist unter der Bedingung, dass  $B$  aufgetreten ist?“. Im Kontext des Qualitätsmanagements verfahrenstechnischer oder fertigungstechnischer Prozessketten können die Ereignisse  $A$  und  $B$  bspw. durch Fehler repräsentiert werden.

Die A-priori-Wahrscheinlichkeiten  $P(A_i)$  bzw  $P(B_j)$  können als Auftretenswahrscheinlichkeiten eines Ereignisses betrachtet werden. Sie lassen sich auf Basis von Vorwissen durch Experten oder mithilfe erhobener Daten ermitteln (HUANG ET AL. 2008, S. 303). A-priori-Wahrscheinlichkeiten oder bedingte Wahrscheinlichkeiten können alternativ auch aus dem Satz der totalen Wahrscheinlichkeit gemäß Gleichung (2.8) errechnet werden (vgl. TAPPE 2013, S. 26).

$$P(B_j) = \sum_{i=1}^n P(B_j|A_i) P(A_i), \quad (2.8)$$

In komplexen Wirkketten mit einer hohen Anzahl von verknüpften Ereignissen kann, als weiterführender Ansatz des Bayes-Theorems, ein sogenanntes Bayessches Netzwerk aufgebaut werden.

Ein Bayessches Netzwerk dient der Berechnung und Darstellung der gemeinsamen Wahrscheinlichkeitsverteilung einer Vielzahl abhängiger Ereignisse (RUSSELL ET AL. 2016, S. 510

---

<sup>9</sup> unter der Voraussetzung von

ff.). Die Darstellung von Bayesschen Netzwerken erfolgt mithilfe von gerichteten azyklischen Graphen. Diese zeichnen sich durch eine definierte Orientierung aus. Abbildung 23 a) stellt ein Beispiel eines solchen Netzwerkes für den Anwendungsfall eines Fahrzeugdefekts dar. Die Ereignisse werden hierbei von Fehlern repräsentiert, welche einen binären Zustand (Fehler ist aufgetreten oder nicht) einnehmen. Die Verbindungen zwischen den Ereignissen stellen Ursachen-Wirkzusammenhänge dar.

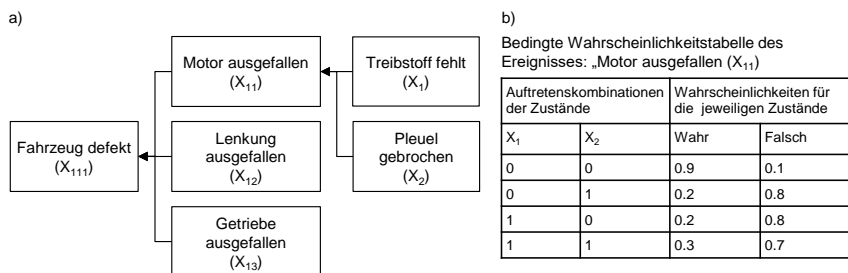


Abbildung 23: a) Beispiel eines diskreten Bayesschen Netzwerkes; b) Bedingte Wahrscheinlichkeitstabelle des Ereignisses „Motor ausgefallen ( $X_{11}$ )“.

Bayessche Netzwerk unterliegen der Annahme, dass die Wahrscheinlichkeitsverteilung eines Ereignisses nur von einer bestimmten Menge an Ereignissen abhängt, nämlich seinen sogenannten Elternknoten<sup>10</sup>  $Pa(X_i) = (X_1^{(i)}, \dots, X_j^{(i)})$  ( $Pa$  von Parents). Unter dieser Annahme berechnet sich die Wahrscheinlichkeitsverteilung wie folgt:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | Pa(X_i)). \quad (2.9)$$

Diese Wahrscheinlichkeitsverteilung kann als Tabelle betrachtet werden, die exemplarisch für einen Fehler in Abbildung 23 b) dargestellt ist. Sie enthält alle Wahrscheinlichkeiten von Auftretenskombinationen der betrachteten Elternknoten  $Pa(X_i)$ . Eine solche Tabelle wird auch als

<sup>10</sup> Elternknoten beschreiben Vorgänger-Ereignisse. Diese wirken auf ein betrachtetes Ereignis. Gemäß Abbildung 23 stellen die Fehler  $X_1$  und  $X_2$  die Elternknoten von  $X_{11}$  dar.



bedingte Wahrscheinlichkeitstabelle bezeichnet. Mithilfe dieser Tabelle und des Bayes-Theorems (Formel (2.7)) lassen sich Bayessche Netzwerk vollständig beschreiben und Ursachenwahrscheinlichkeiten errechnen. (RUSSELL ET AL. 2016, S. 510 ff.)

## 3 Stand der Forschung

Wie in Unterkapitel 1.1 beschrieben wurde, weist die Produktion von Batteriezellen eine hohe Komplexität auf, welche sich in einem signifikanten Produktionsausschuss widerspiegelt (VDMA 2018, S. 38; BRODD & HELOU 2013, S. 298). Um den Produktionsausschuss zu reduzieren, sind Maßnahmen zur unmittelbaren Erkennung von Qualitätsabweichungen und eine Fehler-Ursachen-Analyse erforderlich. In diesem Kapitel wird der Stand der Forschung im Kontext des Qualitätsmanagements für komplexe Prozessketten vorgestellt. Es erfolgt zunächst in Unterkapitel 3.1 eine Klassifizierung und Beschreibung von Bewertungskriterien. Diese bilden die Grundlage für eine systematische Analyse der bestehenden Forschungsansätze, welche in Unterkapitel 3.2 diskutiert werden. In Unterkapitel 3.3 erfolgt eine abschließende Gegenüberstellung der analysierten Ansätze, aus welchen sich der Forschungs- und Handlungsbedarf ableitet (vgl. Unterkapitel 3.4).

### 3.1 Bewertungskriterien

Zur Eingrenzung des Untersuchungsraumes werden Bewertungskriterien definiert, die sich an den in Kapitel 2 beschriebenen Anforderungen im Qualitätsmanagement und den Herausforderungen in der Produktion von Batteriezellen orientieren.

#### Anwendbarkeit in der Batteriezellenproduktion

Dieses Kriterium bezieht sich auf den industriellen Kontext der vorgestellten Forschungsarbeit. Bewertet wird, ob der Ansatz auf die Produktion von Batteriezellen abzielt oder für diesen anwendbar bzw. anpassbar ist. Das Kriterium ist nicht erfüllt, sofern kein Nachweis bzgl. der Anwendbarkeit in einem vergleichbaren industriellen Kontext erbracht werden kann. Gesetzt den Fall, dass die Forschungsarbeit einen zur Batteriezellenproduktion vergleichbaren industriellen Kontext besitzt und die Anwendbarkeit nachgewiesen werden kann, ist das Kriterium teilweise erfüllt. Das Kriterium ist vollständig erfüllt, wenn die Forschung in einem direkten Kontext zu einer Batteriezellenherstellung steht, speziell für diese entwickelt wurde und die Anwendbarkeit nachgewiesen werden konnte.

#### Analyse von Ursachen-Wirkzusammenhängen

Wie in Unterkapitel 1.1 erläutert, bildet das Wissen über Ursachen-Wirkzusammenhänge eine Voraussetzung für das Qualitätsmanagement in komplexen Prozessketten.

Dies impliziert die Identifizierung der Prozesskettenelemente und die Abbildung der Prozessabfolge sowie die Kenntnis von Wirkzusammenhängen zwischen den Prozesskettenelementen (EICHGRÜN 2003, S. 102). Eine Eingrenzung des Untersuchungsraumes von komplexen Prozessketten kann durch die Art von Ursachen-Wirkzusammenhängen erfolgen (vgl. Abbildung 9, Abschnitt 2.2.3).

Bei einer **prozessweisen Analyse** bezieht sich der Untersuchungsraum auf einen bestimmten Prozesskettenabschnitt (WESTERMEIER 2016, S. 14). Analysiert werden hierbei die Beziehungen zwischen den zugehörigen Eingangs- und Ausgangsgrößen. Es erfolgt somit eine klare Abgrenzung zur Analyse der gesamten Prozesskette. Das Kriterium ist nicht erfüllt, sofern bspw. aus Gründen der Komplexitätsreduzierung nicht alle Prozesskettenelemente betrachtet werden. Voraussetzung für eine vollständige Erfüllung des Kriteriums ist die Betrachtung aller, dem Prozessschritt zugeordneten, Prozesskettenelemente.

Untersuchungsgegenstand einer **prozessübergreifenden Analyse** ist die Betrachtung einer vollständigen Prozesskette (WESTERMEIER 2016, S. 14). Das Kriterium ist nicht erfüllt, sofern keine Ansätze zu erkennen sind, welche eine Identifizierung von Ursachen-Wirkzusammenhängen über alle Prozesskettenabschnitte hinweg ermöglichen. Das Kriterium ist vollständig erfüllt, sofern alle Prozesskettenelemente sowie die in Abschnitt 2.2.3 definierten Ausprägungsformen von Wechselwirkungen, wie bspw. direkte, indirekte, einfache oder mehrfache Ursachen-Wirkzusammenhänge betrachtet werden.

Im Weiteren lassen sich Analyseansätze zur Identifizierung von Ursachen-Wirkzusammenhängen nach KORNAS ET AL. 2019A in experten- und datenbasierte Ansätzen kategorisieren.

**Expertenbasierte Ansätze** beschreiben im Zusammenhang der vorliegenden Arbeit Untersuchungsansätze, in welchen das Wissen über Prozesskettenelemente sowie deren Ursachen-Wirkzusammenhänge durch Experten akquiriert wird. Sie repräsentieren dabei eine spezielle qualitativ-deduktive Vorgehensweise, in welcher aus allgemeingültigen Theorien oder Modellen Erkenntnisse für konkrete Fälle abgeleitet werden (vgl. Definition in Unterkapitel 3.2). Der Erfüllungsgrad des Kriteriums wird über den Untersuchungsgrad eines methodischen Ansatzes definiert. Das Kriterium ist nicht erfüllt, sofern keine Anwendung eines expertenbasierten Ansatzes erkennbar ist. Eine vollständige Erfüllung des Kriteriums liegt vor, sofern expertenbasierte Ansätze vollständig beschrieben, in den Kontext einer vorliegenden Arbeit gesetzt und kritisch diskutiert werden.

**Datenbasierte Ansätze** lassen sich den empirischen Untersuchungen zuordnen und dienen dem Wissensgewinn auf Basis erhobener Daten (vgl. SCHÄFER 2003, S. 11). Sie stellen eine spezielle induktive Vorgehensweise dar, in welcher von Einzelfällen ausgehend verallgemeinerte Regeln oder Erkenntnisse abstrahiert werden können (vgl. Definition in Unterkapitel 3.2). Dabei kann eine Unterscheidung in labororientierte und feldorientierte Untersuchungen erfolgen. Bei labororientierten Untersuchungen werden die zu untersuchenden Ursachen-Wirkzusammenhänge durch strenge Konstanthaltung von Versuchsbedingungen und gezielte Veränderung der Eingangsgrößen analysiert (Ceteris-Paribus-Prinzip). In feldorientierten Untersuchungen hingegen werden Daten aus einem realen System ohne gezielte Veränderung bzw. Konstanthaltung von Eingangsgrößen analysiert. Auch hier erfolgt eine Bewertung des Kriteriums anhand des Untersuchungsgrades einer Methode. Demnach ist das Kriterium nicht erfüllt, sofern keine Anwendung datenbasierter Ansätze erkennbar ist. Für eine vollkommene Erfüllung des Kriteriums wird gefordert, dass datenbasierte Ansätze vollständig beschrieben, in den Kontext einer vorliegenden Arbeit gesetzt und kritisch diskutiert werden. (SCHÄFER 2003, S. 15-19)

### Eignung für komplexe Prozessketten

Das Kriterium resultiert aus den Merkmalen komplexer verfahrenstechnischer oder fertigungstechnischer Prozessketten aus Unterkapitel 1.1 und bewertet die

- Anzahl von Prozessarten
- Anzahl von Prozessschritten
- Anzahl von Prozesskettenelementen
- Anzahl und Ausprägungsformen von Ursachen-Wirkzusammenhängen

identifizierter Ansätze in der Forschung. Das Kriterium ist nicht erfüllt, sofern sich keines der genannten Merkmale in der Forschungsarbeit findet. Die Voraussetzung für eine vollständige Erfüllung des Kriteriums ist die Betrachtung aller genannten Komplexitätsmerkmale.

### Eignung für einen Produktionsanlauf

Dieses Kriterium beschreibt die Übertragbarkeit eines Forschungsansatzes für einen Produktionsanlauf. Gemäß Abschnitt 2.2.1 lassen sich zwei Subkriterien ableiten.

Die **Produkt- und Prozess-Generizität** resultiert insbesondere aus den Charakteristiken einer Prototypenproduktion, in welcher unterschiedliche Produkttypen und damit auch Herstellungsprozesse abbildbar sein müssen (KORNAS ET AL. 2019A). Mit dem

Subkriterium soll bewertet werden, ob eine Übertragbarkeit eines Ansatzes bei Produkt- bzw. Prozessänderungen gewährleistet werden kann. Die Produkt- und Prozess-Generizität ist nicht erfüllt, sofern sich der vorgestellte Forschungsansatz nicht auf unterschiedliche Produkt- und Prozesstypen übertragen lässt. Besteht ein generischer Ansatz, in welchem sich weitere Produkt- und Prozesstypen implementieren und analysieren lassen, sowie eine Möglichkeit der Vergleichbarkeit berücksichtigt wird, ist das Subkriterium vollständig erfüllt.

Der mit dem Produktionsanlauf verknüpfte Erkenntnisgewinn über Ursachen-Wirkzusammenhänge fordert eine Möglichkeit zur Erweiterung des gewonnenen Wissens. Eine Bewertung erfolgt dabei mithilfe des Kriteriums der **Skalierbarkeit** (WESTERMEIER 2016, S. 46). Bei Betrachtung expertenbasierter Ansätze ist das Kriterium der Skalierbarkeit nicht erfüllt, sofern keine Eignung für kleine und unsichere Wissensbasen erkennbar ist und kein methodischer Ansatz für eine Erweiterbarkeit von Wissen diskutiert wird. Aus Sicht der datenbasierten Ansätze ist das Kriterium nicht erfüllt, sofern kein methodischer Ansatz vorhanden ist, datenbasierte Modelle um neue Ursachen-Wirkzusammenhänge zu erweitern. Im Falle der Verknüpfung von experten- und datenbasierten Ansätzen ist zu bewerten, ob ein methodischer Ansatz gegeben ist, um diese beiden Domänen zusammenzuführen, sodass Ursachen-Wirkzusammenhänge angepasst und erweitert werden können.

### **Vollständigkeit des Qualitätsmanagementsystems**

Als Leitfaden zur Steigerung der Qualität in Unternehmen wird in der DIN EN ISO 9004 2018-4 die Spezifizierung und Selbstbewertung von Qualitätskriterien empfohlen. Auf Grundlage dieser Bewertung kann eine Aussage über die Effizienz und den Reifegrad eines Qualitätsmanagementsystems getroffen werden. In Analogie zu dieser Vorgehensweise dient das Kriterium *Vollständigkeit des Qualitätsmanagementsystems* einer Einordnung des Leistungsniveaus von Qualitätsmanagementkonzepten. Das Kriterium ist nicht erfüllt, sofern kein ganzheitlicher systematischer Ansatz erkennbar ist, welcher zu einer Qualitätssteigerung führt. Für eine vollständige Erfüllung müssen nachfolgende Subkriterien gegeben sein, welche sich aus den Charakteristiken einer Qualitätssteuerung ableiten lassen (vgl. WILHELM 2006, S. 33):

- Feststellung von Prozessänderungen auf Grundlage der **Implementierung von KPIs**
- Reaktiver oder proaktiver Ansatz zur **Fehler-Ursachen-Analyse**
- Systematischer Ansatz zur Führung verfahrenstechnischer und fertigungstechnischer Prozessketten und zur **kontinuierlichen Qualitätssteigerung**

### Praxistauglichkeit

Zur Gewährleistung der Umsetzbarkeit der in einer Forschungsarbeit beschriebenen Methodik wird das Kriterium *Praxistauglichkeit* eingeführt. Das Kriterium ist nicht erfüllt, sofern eine Anwendbarkeit der Methode in der Praxis nicht unterstützt wird. Das Kriterium ist vollständig erfüllt, sofern die Methodik in der Praxis aufgrund einer den Anwendern unterstützenden Strukturierung erfolgreich umgesetzt werden kann. Dies impliziert eine Nachvollziehbarkeit des Methodenablaufes sowie eine einfache sowie zeit- und ressourceneffiziente Durchführbarkeit. Im Weiteren kann auch die Verwendung etablierter Softwarelösungen den Umsetzungsaufwand reduzieren. Im Zusammenhang mit expertenbasierten Ansätzen wird eine Praxistauglichkeit insbesondere durch strukturierte und effektive Wissensakquisition erreicht. (WESTERMEIER 2016, S. 43)

## 3.2 Diskussion bestehender Ansätze in der Forschung

Zur Eingrenzung des Untersuchungsraumes werden die Forschungsansätze anhand der in Abbildung 24 dargestellten Gruppierung diskutiert. Die Gruppierung lässt sich aus den zuvor thematisierten Bewertungskriterien ableiten und stellt die unterschiedlichen Pole von Analysekonzepten dar.

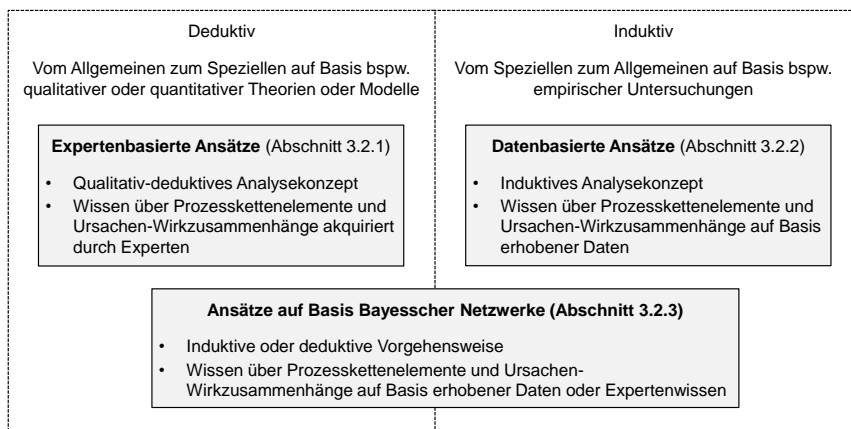


Abbildung 24: Eingrenzung des Untersuchungsraumes anhand methodischer Ansätze.

Im Falle eines deduktiven Analysekonzepts werden aus allgemeingültigen Theorien oder Modellen die Erkenntnisse für einen konkreten Fall qualitativ oder quantitativ abgeleitet (WESTERMEIER 2016, S. 19). Ishikawa-Diagramme oder Beziehungsmatrizen stellen bspw. häufig eingesetzte qualitativ-deduktive Modelle fertigungstechnischer- oder verfahrenstechnischer Prozessketten dar (vgl. SCHÄFER 2003, S. 12). **Expertenbasierte Ansätze** repräsentieren im Kontext dieser Arbeit eine spezielle Form qualitativ-deduktiver Analysekonzepte, in welchen Ursachen-Wirkzusammenhänge auf Basis von Expertenwissen ermittelt werden (vgl. SCHÄFER 2003, S. 12). Es sei hervorzuheben, dass die expertenbasierten Ansätze nicht mit Expertensystemen gleichzusetzen sind. Während mit dem Begriff der expertenbasierten Ansätze eine spezielle Vorgehensweise zur Analyse von Prozessketten auf Basis von Expertenwissen gemeint ist, repräsentieren Expertensysteme „[...] ein informationstechnisches System, das in einem gegebenen Spezialisierungs- oder Problembereich menschliche Experten in Bezug auf ihr Wissen und ihre Schlussfolgerungen nachbildet [...]“ (ULLMANN 2010, S. 28).

Dem deduktiven Vorgehen gegenüber steht das induktive Vorgehen. Hierbei werden von Einzelfällen ausgehend verallgemeinerte Erkenntnisse abgeleitet (SCHÄFER 2003, S. 10). **Datenbasierte Ansätze** stellen eine spezielle Form der induktiven Vorgehensweise dar, in welcher Regeln und Erkenntnisse auf Basis erhobener Daten ermittelt werden (vgl. SCHÄFER 2003, S. 9–11 und WESTERMEIER 2016, S. 19–21).

**Bayessche Netzwerke** stellen eine gesonderte Gruppierung der Forschungsansätze dar und lassen sich induktiv oder deduktiv sowie auf Basis von Expertenwissen oder Daten aufbauen. Für eine Übersicht der möglichen Ansätze zur Analyse von Ursachen-Wirkzusammenhängen in verfahrenstechnischen oder fertigungstechnischen Systemen sei auf die Arbeiten von SCHÄFER und WESTERMEIER verwiesen (SCHÄFER 2003, S. 9–20; WESTERMEIER 2016, S. 19–20).

### 3.2.1 *Expertenbasierte Ansätze*

SCHÄFER verfolgt das Ziel, die Prozesssicherheit in komplexen fertigungstechnischen Prozessketten durch die Beseitigung von Fehlerursachen und Schwachstellen zu steigern (SCHÄFER 2003, S. 1). Der diskutierte Anwendungsfall bezieht sich auf den Produktionsbereich der Blechbeschichtung. Mithilfe einer zunächst deduktiv-qualitativen Vorgehensweise soll eine prozessübergreifende Analyse ermöglicht werden. Im Rahmen der deduktiven Vorgehensweise erfolgt zunächst eine Vorwärtsmodellierung, in welcher von möglichen Ursachen auf Wirkungen geschlossen wird. Direkte Wirkzusammenhänge zwischen Prozess- und Produkteigenschaften werden dabei mithilfe von Ishikawa-Diagrammen, Relationendiagrammen

und Baumdiagrammen identifiziert (SCHÄFER 2003, S. 43). Nachfolgend wird das System unter Anwendung bspw. einer FMEA oder Fehlerbaumanalyse rückwärts modelliert, um von der Wirkung auf mögliche Ursachen zu schließen (SCHÄFER 2003, S. 43-44). Zur vollständigen Identifizierung aller Prozesskettenelemente werden die Ergebnisse der Vor- und Rückwärtsmodellierung zusammengefasst. Allerdings wird in der Forschungsarbeit von SCHÄFER (2003) nicht erläutert, wie die durch die unterschiedlichen Methoden identifizierten Ursachen-Wirkungszusammenhänge miteinander verknüpft werden. Aufbauend auf den Ursachen-Wirkungszusammenhängen wird für die Analyse von Fehlerursachen und Schwachstellen eine an das House of Quality angelehnte Einfluss-Wirkungsmatrix verwendet (SCHÄFER 2003, S. 45). In den jeweiligen Feldern der Matrix wird zusätzlich anhand von Expertenaussagen bewertet, ob Ursachen-Wirkungszusammenhänge vermutet oder bereits nachgewiesen sind. Hieraus sollen sich Erkenntnislücken ableiten lassen, welche die Grundlage für eine nachfolgende Analyse bilden. Bestandteil dieser Analyse sind empirische Untersuchungen, insbesondere feldorientierte und statistische Analyseansätze. Es wird hierbei zwar die Anwendbarkeit möglicher Methoden diskutiert, jedoch nicht auf die Details der Methodenanwendung oder -umsetzung eingegangen (SCHÄFER 2003, S. 71). Wie die gewonnenen Erkenntnisse einer empirischen Untersuchung in die Einfluss-Wirkungsmatrix zurückgeführt werden oder für eine Fehler-Ursachen-Analyse nutzbar gemacht werden können, bleibt ebenfalls offen. Der Fokus der Forschungsarbeit von SCHÄFER (2003) liegt somit vorwiegend auf der Erarbeitung eines expertenbasierten Ansatzes. Dabei werden keine indirekten Ursachen-Wirkungszusammenhänge thematisiert, welche wesentlich sind, um mehrstufige Auswirkungen prozessübergreifend zu analysieren (WESTERMEIER 2016, S. 2). Da die Verwendung von KPIs in der Arbeit nicht berücksichtigt wird, erfüllt die vorgestellte Methode auch nicht die Anforderung an ein ganzheitliches Qualitätsmanagementsystem.

EICHGRÜN fokussiert seine Forschung auf die deduktiv-qualitative Analyse von prozessübergreifenden Ursachen-Wirkungszusammenhängen mit dem Ziel, die Prozesssicherheit zu steigern (EICHGRÜN 2003, S. 1). Die Methode wird anhand einer fertigungstechnischen Prozesskette zur Herstellung von PKW-Motorventilen konkretisiert. Dabei wird jedoch nicht auf den Komplexitätsgrad in Bezug auf die Anzahl von Prozesskettenelementen oder Ursachen-Wirkungszusammenhängen eingegangen. Das von EICHGRÜN (2003) entwickelte Konzept stellt drei relevante Schwerpunkte dar. Im Fokus des ersten Forschungsschwerpunktes steht die Erarbeitung eines Werkstückmodells. In diesem lässt sich der Soll- und Istzustand eines Fertigteiltes abbilden sowie Eigenschaften zu den Beschreibungsdimensionen Geometrie, Oberfläche, Randzone und Werkstückkern spezifizieren. Vorteil dieses Werkstückmodells ist die Möglichkeit einer generischen Anwendung für weitere Werkstücktypen. Eine Übertragung dieses Ansatzes auf einen vollständigen Produktionsanlauf ist allerdings nur bedingt möglich, da hierfür



geforderte Spezifikationen zu Beginn einer Prototypenproduktion oftmals nicht vorliegen. Im Fokus des zweiten Forschungsschwerpunktes steht die Erarbeitung eines auf Expertenwissen basierenden Prozess- und Strukturmodells. In diesem werden zunächst die Prozessabfolgen sowie produktionstechnische Schnittstellen definiert. Dabei wird auf eine Systemanalyse mit Hilfe der Structured Analysis and Design Technique zurückgegriffen. Die Modellierung der Ursachen-Wirkungszusammenhänge bildet den dritten Schwerpunkt der Forschungsarbeit und erfolgt mit Hilfe einer auf dem House of Quality basierenden Bewertungsmatrix (EICHGRÜN 2003, S. 85). Hierdurch lassen sich prozessübergreifende Ursachen-Wirkzusammenhänge, wie bspw. der Zusammenhang zwischen mechanischen Eigenschaften und Prozessparametern, abbilden. Allerdings werden dabei keine indirekten Ursachen-Wirkzusammenhänge zur Analyse prozessübergreifender Auswirkungen berücksichtigt. Die in der Matrix abgelegten Ursachen-Wirkzusammenhänge werden im Vorfeld von Projektteams mit Mitgliedern aus verschiedenen Fachbereichen bewertet, wobei auf Methoden wie die FMEA zurückgegriffen wird. Allerdings bleibt unbeantwortet, wie die von den Experten akquirierten Zusammenhänge methodisch in die Bewertungsmatrix übertragen werden. Auch eine Praxistauglichkeit der Methode, bspw. im Rahmen einer softwaretechnischen Umsetzung, konnte nicht nachgewiesen werden. Zudem erfolgte kein methodisches Zusammenführen des Konzepts mit datenbasierten Analysemethoden. Es wird hier lediglich die Anwendbarkeit möglicher Methoden diskutiert (EICHGRÜN 2003, S. 65-66).

Mit dem konkreten Anwendungsfall in einer Batteriezellenproduktion stellt WESTERMEIER (2016) abgeleitet aus den Erkenntnissen der Publikationsreihe WESTERMEIER ET AL. 2013, WESTERMEIER ET AL. 2014 sowie REINHART ET AL. 2014, eine Methode zur qualitätsorientierten Analyse komplexer Prozessketten vor. Im Fokus der Arbeit steht ein an die FMEA angelehnter, deduktiv-qualitativer Analyseansatz. Aufbauend auf dem identifizierten Defizit einer unzureichenden Betrachtung von indirekten Ursachen-Wirkzusammenhängen steht eine ganzheitliche Prozesskettenanalyse im Vordergrund. Die in der Arbeit entwickelte Methode untergliedert sich in die Module Wissensakquisition, Wissensinterpretation und empirische Analyse. Im Modul der Wissensakquisition werden zunächst finale Produkteigenschaften, wie bspw. das Zellgewicht oder die Zellkapazität, spezifiziert. Im nächsten Schritt erfolgt die Identifizierung aller Prozesskettenelemente sowie derer Ursachen-Wirkungszusammenhänge. Dabei werden direkte Ursachen-Wirkzusammenhänge mithilfe einer Expertenbefragung ermittelt. Für jeden Ursachen-Wirkzusammenhang werden hierbei die Einflussstärke, Auftretenswahrscheinlichkeit sowie eine Selbstbewertung bezüglich der Aussagesicherheit zur Einflussstärke und Auftretenswahrscheinlichkeit abgefragt. Zur strukturierten Ablage der Informationen wird eine Matrix verwendet. Indirekte Ursachen-Wirkzusammenhänge werden mithilfe eines aus der Graphentheorie stammenden Pfadsuch-Algorithmus errechnet. Dabei wird auf Basis der

Matrix ein Durchschnittswert der Einflussstärken entlang der Kette von Ursachen-Wirkzusammenhängen gebildet. Auf Grundlage der Matrix lassen sich im Modul der Wissensinterpretation, nach der Berechnungen von Zeilen- und Spaltensummen, Aussagen über die globale Relevanz von Prozesskettenelementen treffen. Zuletzt erfolgt in der Forschungsarbeit von WESTERMEIER im Modul der empirischen Analyse eine Validierung der expertenbasierten Bewertungen mithilfe einer datenbasierten Regressionsanalyse (WESTERMEIER 2016, S. 65). Die Regressionsmodelle werden dabei mit den bewerteten Einflussstärken und Auftretenswahrscheinlichkeiten eines jeweiligen Ursachen-Wirkzusammenhangs zusammengeführt. Die von WESTERMEIER vorgelegte Forschungsarbeit erhebt den Anspruch zur Anwendung während eines vollständigen Produktionsanlaufs (WESTERMEIER 2016, S. 3). Der Mehrwert der Forschungsarbeit spiegelt sich insbesondere im Planungs- und Auslegungsprozess einer Prozesskette wider, zu deren Betrieb im Unternehmen keine Erfahrungen vorliegen (WESTERMEIER 2016, S. 3). Die Methodik hilft insbesondere durch das Modul der Wissensinterpretation im Planungs- und Realisierungsprozess einer frühen Entwicklungsphase, kritische Prozesskettenabschnitte und Prozesskettenelemente zu beleuchten. Obwohl der vorgestellte Ansatz Parallelen zur FMEA aufweist, wird nicht die Vernetzung von Fehlern, sondern lediglich die Vernetzung von Prozesskettenelementen beurteilt. Der vorgestellte Ansatz ist somit für Fehlerdiagnosen ungeeignet, auch weil Kennzahlensysteme zur Identifizierung von Fehlerursachen nicht berücksichtigt werden. Somit bietet die beschriebene Forschungsarbeit zwar eine Möglichkeit zur qualitätsorientierten Analyse, stellt aber kein Konzept eines umfassenden Qualitätsmanagements dar. Zuletzt werden auch die datenbasierten Ansätze für die Identifizierung von Ursachen-Wirkzusammenhängen unter dem Aspekt eines vollständigen Produktionsanlaufes unzureichend untersucht. WESTERMEIER verwendet lediglich labororientierte Analyseverfahren (WESTERMEIER 2016, S. 101), welche zwar für eine prozessweise Analyse anwendbar sind, sich jedoch nicht für komplexe Prozessketten mit prozessübergreifenden Ursachen-Wirkzusammenhängen eignen. Dies lässt sich dadurch begründen, dass der Aufwand von Experimenten in labororientierten Untersuchungen mit der Anzahl der zu betrachtenden Prozessparameter exponentiell steigt (MOLLENHAUER 2007, S. 163).

SCHNELL & REINHART (2016) stellen, aufbauend auf dem von WESTERMEIER (2016) erarbeiteten Ansatz, ein Qualitätsmanagementkonzept für die Batteriezellenproduktion vor. Im Zentrum der Veröffentlichung steht die Identifizierung von Quality Gates. Diese stellen Messpunkte dar, welche dazu dienen sollen, eine Vielzahl qualitätsrelevanter Prozessparameter aggregiert zu untersuchen. Quality Gates zielen somit darauf ab, den Aufwand für Qualitätskontrollen in komplexen verfahrenstechnischen und fertigungstechnischen Prozessketten zu minimieren. Durch das Erkennen von Abweichungen in frühen Prozesskettenabschnitten soll im Sinne ei-

ner proaktiven Prozessführung eine Reduzierung des Ausschusses erreicht werden. Die hierfür notwendigen Erkenntnisse über Ursachen-Wirkzusammenhänge sollen dabei aus dem von WESTERMEIER (2016) erarbeiteten Ansatz gewonnen werden. Unklar bei dem von SCHNELL & REINHART vorgestellten Konzept ist jedoch, wie dabei Toleranzgrenzen identifiziert werden sollen, welche eine Voraussetzung für die Qualitätsprüfung auf Grundlage von Quality Gates darstellen (SCHÜPPSTUHL 2018, S. 100). Dies ist insbesondere hinsichtlich einer Anwendung in der frühen Phase des Produktionsanlaufs kritisch zu betrachten, in welcher wenig Prozesswissen bzw. Daten vorliegen, um Toleranzgrenzen zu bestimmen (KORNAS ET AL. 2019A, S. 382). Ungeklärt bleibt ebenfalls, wie auf Basis der von WESTERMEIER (2016) ermittelten Ursachen-Wirkzusammenhänge auf die Quality Gates geschlossen werden soll. Zuletzt wird auch kein Nachweis bezüglich einer Umsetzbarkeit erbracht. Die Forschungsarbeit nach SCHNELL & REINHART (2016) wird lediglich auf konzeptioneller Ebene diskutiert und findet keine industriennahe Anwendung.

### 3.2.2 Datenbasierte Ansätze

Die Publikationsreihen von GROßMANN & WIEMER (2010), GROßMANN ET AL. (2012) und GROSSMANN (2014) setzt den Fokus auf eine datenbasierte Analyse von Ursachen-Wirkzusammenhängen mit dem Ziel, die Reproduzierbarkeit in fertigungstechnischen Prozessketten zu erhöhen. Schwerpunkt der Forschungsarbeiten ist eine Prozesskettenbeschreibung sowie eine Datenerfassung und -analyse. Ein zentrales Element bildet ein Prozesskettenmodell, in welchem eine Verknüpfung von Prozesskettenelementen mit Produktionsdaten stattfindet (GROßMANN & WIEMER 2010, S. 956). Zur Analyse von Ursachen-Wirkzusammenhängen wird auf die statistische Versuchsplanung zurückgegriffen (GROßMANN ET AL. 2013, S. 37). Die Daten werden somit im Sinne eines labororientierten Ansatzes aus Experimenten gewonnen. Für direkte, indirekte, einfache oder mehrfache Ursachen-Wirkzusammenhänge sollen auch weitere Möglichkeiten der Datenanalyse bereitstehen, auf welche jedoch nicht eingegangen wird. Auch stellt die Publikationsreihe keine Methodenunterstützung für die Akquisition von Expertenwissen bereit, welche für die Prozesskettenbeschreibung benötigt wird (GROßMANN ET AL. 2013, S. 37).

Aktuelle Veröffentlichungen zur Analyse von Ursachen-Wirkzusammenhängen weisen eine Tendenz zur Verwendung feldorientierter Ansätze auf, wie bspw. aufgezeigt in FABIŚ-DO-MAGAŁA ET AL. 2019, SAMEK ET AL. 2017, EVANS & BORELAND 2015, RENU ET AL. 2016 und FEURER ET AL. 2015.

Mithilfe feldorientierter Untersuchungen wurde durch SCHNELL ET AL. (2019) erstmals die Anwendbarkeit von Data-Mining-Methoden zur Analyse und Optimierung des Produktionsprozesses von Batteriezellen nachgewiesen. Die Forschungsarbeit stützt sich auf ein für das Data-Mining standardisiertes Prozessmodell, CRISP-DM, in welchem Batteriezellen einer Prototypenproduktion die Datengrundlage für die Analyse bilden. Mit der Datenanalyse wird beabsichtigt zu identifizieren, welche Prozesskettenelemente ausgewählte Zielgrößen der Batteriezelle beeinflussen. Auf Basis einer Modellinterpretation durch Prozessexperten, werden unterschiedliche Methoden des Data-Minings miteinander verglichen. Verallgemeinerte lineare Modelle ermöglichen in dem Anwendungsbeispiel, die Einflüsse auf die Kapazität einer Batteriezelle zu identifizieren. Aus Gründen der Modellinterpretation werden allerdings vielversprechende Methoden des Data-Minings, wie Gradient Boosted Trees, Deep Neural Networks oder Random Forests in der Studie ausgeschlossen.

Einen ebenfalls feldorientierten Ansatz zur Analyse und Optimierung des komplexen Produktionsprozesses von Batteriezellen stellen THIEDE ET AL. (2019) im Rahmen des Forschungsprojektes DaLion 4.0 (Data-Mining in der Produktion von Lithium-Ionen-Batteriezellen 4.0) vor. Im Gegensatz zu der Forschungsarbeit von SCHNELL ET AL. (2019) steht hier eine Analyse mehrerer Zielgrößen im Vordergrund. Den Kernbaustein bildet ein Entscheidungsunterstützungsmodul, in welchem dem Prozessexperten Methoden der visuellen Analyse, wie bspw. Korrelationsmatrizen oder Choroplethenkarten zur Verfügung gestellt werden (THIEDE ET AL. 2019, S. 4). Darüber hinaus erhält der Prozessexperte Unterstützung durch eine Portfolioanalyse, in welcher statistische Kenngrößen für ausgewählte Zielgrößen dargelegt werden. Diese Visualisierungsform bietet dem Prozessexperten die Möglichkeit, eine multikriterielle Perspektive einzunehmen. Im Fokus der Forschungsarbeit steht ähnlich zu WESTERMEIER (2016) die Identifizierung qualitätsrelevanter Prozesskettenelemente, jedoch kein umfassender Ansatz eines Qualitätsmanagementsystems. Weitere Methoden der Datenanalyse im Kontext des Forschungsprojektes DaLion 4.0 werden in den Arbeiten von TURETSKY ET AL. (2018, 2019 und 2020) sowie FILZ ET AL. (2020) untersucht.

MEYER ET AL. (2019) schlägt für eine multikriterielle Analyse in der Prozesskette von Batteriezellen die Verwendung von Wünschbarkeitsfunktionen vor. Entgegen dem Ansatz von THIEDE ET AL. 2019, welcher sich einer deskriptiven bzw. diagnostischen Analyse zuordnen lässt, ermöglicht die Verwendung von Wünschbarkeitsfunktionen eine Prädiktion von Zielgrößen (STEUER 1999). Zudem stellen Wünschbarkeitsfunktionen eine Möglichkeit dar, Expertenwissen in mathematische Optimierungen zu integrieren. Auf Grundlage von Regressionsanalysen wird berechnet, auf Basis welcher Eingangsgrößen die von den Experten spezifizierten Ausgangsgrößen erzielt werden. Obwohl der Ansatz vielversprechend für die Analyse von komplexen Prozessketten zu sein scheint, wird die Anwendbarkeit lediglich für einen einzelnen

Prozesskettenabschnitt nachgewiesen. Auch wird die Eignung der Methode für eine frühe Phase des Prozessanlaufes nicht untersucht. Zudem beschreibt die Forschungsarbeit von MEYER ET AL. (2019) unzureichend, wie eine Schnittstelle zur Akquisition des Expertenwissens zu gestaltet ist. Es wird bspw. keine Softwarelösung vorgestellt, welche die Praxistauglichkeit fördern könnte.

Im Zentrum der Forschungsarbeiten von GRÖGER steht die datenbasierte Optimierung von Fertigungsprozessketten (GRÖGER ET AL. 2012; GRÖGER ET AL. 2013; GRÖGER ET AL. 2014A; GRÖGER ET AL. 2014B; GRÖGER 2015). Die Arbeiten umfassen insgesamt drei Forschungsschwerpunkte, welche als Gesamtansatz in einer Architektur zusammengeführt werden (vgl. GRÖGER 2015). Der erste Schwerpunkt adressiert die Datenbereitstellung und zielt darauf ab, eine Wissensdatenbank für die Fertigung zu generieren (GRÖGER ET AL. 2012, GRÖGER ET AL. 2014A, 2014B). Die Wissensdatenbank umfasst die Integration von strukturierten und unstrukturierten Daten im Sinne eines Data Warehouse-Ansatzes, wie auch dargestellt von THIEDE ET AL. (2019). Der Kern des zweiten Forschungsschwerpunktes baut auf der Wissensdatenbank auf und dient einer Prozessanalyse. Im Fokus stehen generische Methoden für deskriptive und prädiktive Analyseverfahren. Im Falle einer Qualitätsabweichung wird auf Grundlage der Analysemethoden eine datenbasierte Generierung von Handlungsempfehlungen ermöglicht. Gegenstand des dritten Forschungsschwerpunktes ist die Entwicklung eines Analysedienstes in Form eines Dashboards, um Informationen für die Fertigungsleitebene bereitzustellen (GIEBLER ET AL. 2019, GRÖGER ET AL. 2013). Die Forschungsarbeiten von GRÖGER spiegeln somit den Ansatz eines Qualitätsmanagementsystems wider, in welchem KPIs implementiert, Möglichkeiten einer reaktiven oder proaktiven Fehler-Ursachen-Analyse dargestellt sowie ein systematisches Vorgehen zur Führung einer Prozesskette abgebildet werden. Eine prototypische Implementierung des Konzepts erfolgt am Beispiel der Fertigungsprozesskette von Nockenwellen. Eine Eignung des von GRÖGER (2015) entwickelten Konzepts für einen Produktionsanlauf wird nicht diskutiert. Für den Aufbau der Modelle wird auf ein umfangreiches und multidimensionales Datenmodell zurückgegriffen, in welchem operative und prozessorientierte Daten ganzheitlich abgebildet werden (GRÖGER 2015, S. 106, S. 225). Inwiefern sich dieses Konzept für eine frühe Phase eines Produktionsanlaufes eignet, welche gemäß Abschnitt 2.2.2 durch eine geringe Datenverfügbarkeit gekennzeichnet ist, bleibt unbeantwortet. Auch eine Einbindung von Expertenwissen zur ganzheitlichen Identifizierung von Ursachen-Wirkzusammenhängen wird in dem Ansatz von GRÖGER nicht berücksichtigt.

### 3.2.3 Ansätze auf Basis Bayesscher Statistik

Die Forschungsarbeit von RASHIDY (2007) lässt sich als Schnittstelle zwischen expertenbasierten und datenbasierten Qualitätsmanagementmethoden einordnen und beinhaltet Ansätze der Bayesschen Statistik. Es wird ein Konzept vorgestellt, das zur Fehler- und Ursachenidentifikation in der Serienproduktion des Karosseriebaus einsetzbar ist. Die Methodik untergliedert sich in ein Fehlererkennungs-, Fehleridentifikations- und Entscheidungsmodul. Im Fehlererkennungsmodul werden Prozesskettenelemente einer laufenden Produktion gemessen und in einem neuronalen Netz aus univariater und multivariater Perspektive analysiert. Das Fehleridentifikationsmodul beruht auf einem Expertensystem, in welchem basierend auf einer Fuzzy-Logik (vgl. ZADEH 1965) und FMEA die Ursachen für Fehler erkannt werden sollen. Zuletzt werden dem Anwender im Entscheidungsmodul Handlungsempfehlungen bereitgestellt. Diese dienen der Überprüfung, ob basierend auf den identifizierten Fehlerursachen, Prozessanpassungen durchzuführen sind oder Prozesse ohne Veränderung durchlaufen werden können. Die Handlungsempfehlungen stützen sich dabei auf die Berechnung bedingter Wahrscheinlichkeiten auf Basis des Bayes-Theorems. Eingang für die Berechnung bilden einerseits die im Rahmen der FMEA bewerteten Auftretenswahrscheinlichkeiten von Fehlern sowie Kennzahlen bezüglich der statistischen Modellgenauigkeit, welche aus dem Fehleridentifikationsmodul resultieren. Die Eignung von statistischen Modellgenauigkeiten für die Berechnungen bedingter Wahrscheinlichkeiten wird allerdings nicht diskutiert und ist angesichts der Definition des Bayes-Theorems kritisch zu betrachten (HESSE 2003, S. 51-52). Zudem adressiert die Forschungsarbeit von RASHIDY (2007) ebenfalls keinen Produktionsanlauf. Im Fokus steht die Analyse einer Serienproduktion, welche charakterisiert ist durch eine hohe Datenverfügbarkeit und somit die Fehlererkennung auf Basis neuronaler Netze ermöglicht (RASHIDY 2007, S. 64-69). Allerdings wird in der exemplarischen Anwendung lediglich ein Prozesskettenabschnitt betrachtet, weshalb auch das Kriterium der Eignung für komplexe Prozessketten nicht erfüllt werden kann (RASHIDY 2007, S. 121-122).

Um die statistische Abhängigkeit einer Vielzahl von Prozesskettenelementen zu betrachten, lässt sich ausgehend vom Bayes-Theorem ein Bayessches Netzwerk erstellen (Abschnitt 2.2.10) (RUSSELL ET AL. 2016, S. 510 ff.). Für die Berechnung eines solchen Netzwerkes können, wie nachfolgend diskutiert, expertenbasierte oder datenbasierte Wahrscheinlichkeiten genutzt werden (DIALLO ET AL. 2018, S. 585).

Aufbauend auf einer Design-FMEA stellt LEE (2001) einen expertenbasierten Ansatz vor, um statistische Abhängigkeiten in mechatronischen Systemen auf Basis eines Bayesschen Netzwerkes abzubilden. Der Fokus wird, am Beispiel der Entwicklung eines Druckers, auf die Identifizierung von Konstruktionsfehlern gelegt. In der prototypischen Umsetzung bilden ca. 200

Fehlerbilder die Grundlage für das Bayessche Netzwerk (LEE 2001, S. 14). Eine Übertragung des vorgestellten Forschungsansatzes auf das Qualitätsmanagement in komplexen Prozessketten ist allerdings nur bedingt durchführbar. Zwar ermöglicht der Forschungsansatz auf Basis der Design-FMEA eine methodische Identifizierung von Fehlern sowie, mittels des Bayesschen Netzwerkes, eine Analyse von Ursachen-Wirkzusammenhängen. Jedoch beinhaltet das vorgestellte Konzept zwei wesentliche Limitierungen. Wie in Abschnitt 2.2.10 erläutert, werden zum Aufbau eines Bayesschen Netzwerkes bedingte Wahrscheinlichkeitstabellen benötigt, in welchen für jeden Fehlerknoten die Kombination von Zuständen der dazugehörigen Elternknoten vorhanden sein müssen. Die Größe der Wahrscheinlichkeitstabelle steigt exponentiell mit der Anzahl an Elternknoten (ABRAHAM 2017, S. 100). In dem von LEE (2001) vorgestellten Forschungsansatz werden die bedingten Wahrscheinlichkeitstabellen lediglich mithilfe von Expertenbewertungen aufgestellt, was einen hohen Bewertungsaufwand erfordert. Eine solche Vorgehensweise wird von SRINIVAS (1993) kritisiert, da die Qualität der Expertenbewertung durch die hohe Anzahl von Bewertungen beeinträchtigt werden kann. Eine weitere Limitierung der Forschungsarbeit bezieht sich auf das mögliche Auftreten von Widersprüchen in der Akquisition des Expertenwissens (LEE 2001, S. 14). Widersprüche können auftreten, wenn Experten eines jeweiligen Bereiches nicht in der Lage sind, die Wechselwirkungen ihrer Bewertungen über andere Bereiche hinweg zu berücksichtigen. Diese Form von Widersprüchen wird als Inkonsistenz bezeichnet und in der Forschungsarbeit von LEE (2001) nicht gelöst.

Das Problem des exponentiellen Wachstums von Wahrscheinlichkeitstabellen, welche für die Berechnung von Bayesschen Netzwerken benötigt werden, ist Forschungsbestandteil der Veröffentlichung von ZAGORECKI & DRUZDZEL (2013). Einen möglichen Lösungsansatz zur Komplexitätsreduzierung stellen die sogenannten Noisy-OR Gates dar (vgl. Abschnitt 4.4.2). Die Veröffentlichung von ZAGORECKI & DRUZDZEL (2013) betrachtet Bayessche Netzwerke und Noisy-OR Gates aus theoretischer Perspektive, ohne industriennahe Anwendung. Ein Nachweis zur Anwendbarkeit im Kontext einer Analyse von Ursachen-Wirkzusammenhängen wird hierbei nicht erbracht.

Weitere Ansätze, um eine FMEA als Grundlage zum Aufbau eines Bayesschen Netzwerkes zu verwenden werden von GABRIEL ET AL. (2012) sowie OLIVA ET AL. (2010) vorgestellt. Ungeklärt bleibt in diesen Forschungsarbeiten, wie eine methodische Übertragung der Bewertungskennzahlen einer FMEA auf die benötigten Wahrscheinlichkeiten zum Aufbau des Bayesschen Netzwerkes erfolgen kann.

Eine industriennahe Anwendung von Bayesschen Netzwerken zur Analyse von Ursachen-Wirkzusammenhängen steht im Mittelpunkt der Forschungsarbeit von McNAUGHT & CHAN (2011).

Ziel der Veröffentlichung ist die Schärfung des Bewusstseins in Forschung und Industrie, Bayessche Netzwerke als Entscheidungsunterstützung zu verwenden. Demnach wird insbesondere ein Mehrwert in der Anwendung von Bayesschen Netzwerken in Industriebereichen erzielt, in denen die Unkenntnis über Ursachen-Wirkzusammenhängen zu hohen Unsicherheiten führt. Wahrscheinlichkeitstabellen werden auf Basis der in ZAGORECKI & DRUZDZEL (2013) diskutierten Noisy-OR Gates berechnet. Die Forschungsarbeit baut auf einem expertengestützten Ansatz auf, um notwendige Wahrscheinlichkeiten zu akquirieren. Die Wissensakquisition wird allerdings nicht methodisch unterstützt, wie bspw. durch die Verknüpfung einer FMEA. Ein solches Vorgehen ist deshalb bei komplexen Prozessketten mit einer hohen Anzahl von Prozesskettenelementen kritisch zu bewerten. Im Anwendungsbeispiel der Forschungsarbeit von ZAGORECKI & DRUZDZEL (2013) wird die Verwendung von Bayesschen Netzwerken zur Fehlerdiagnose während eines Systemtests von Empfangsstationen der Firma Motorola diskutiert. Auf die Anzahl von Fehlerknoten wird dabei nicht eingegangen.

Die Veröffentlichung von ASMA ET AL. (2014) stellt einen datenbasierten Ansatz zum Aufbau eines Bayesschen Netzwerkes im Kontext der Halbleiterindustrie vor. Im Fokus steht die Analyse von Ursachen-Wirkzusammenhängen auf Basis von Produkt-, Prozess- und Instandhaltungsdaten. Es werden unterschiedliche Algorithmen angewendet, um die Struktur des Bayesschen Netzwerkes aufzubauen und zu optimieren. ASMA ET AL. (2014) diskutiert ebenfalls die Implementierung von Prozessfähigkeitsindizes als Möglichkeit zur Fehlererkennung. Allerdings wird in der Forschungsarbeit das Kriterium der Eignung für einen Produktionsanlauf nicht erfüllt, da auch hier lediglich eine Serienproduktion betrachtet wird. Des Weiteren wird kein Nachweis für die Anwendbarkeit des Konzepts in komplexen Prozessketten erbracht, da in dem dargestellten Anwendungsfall Netzwerke mit < 50 Fehlerknoten betrachtet werden.

In Bezug auf datenbasierte Bayessche Netzwerke lässt sich zusammenfassen, dass die Betrachtung einer geringen Anzahl von Fehlerknoten eine entscheidende Limitierung der Anwendbarkeit in komplexen Prozessketten darstellt. Dies spiegelt sich auch in den Arbeiten von KABIR ET AL. (2016), MA ET AL. (2014) und IDE & COZMAN (2008) wider.

Konzepte, welche zum Aufbau eines Bayesschen Netzwerkes zugleich auf experten- sowie datenbasierten Ansätze zurückgreifen, sind in den Forschungsarbeiten von HUANG ET AL. (2008) sowie LI & SHI (2007) zu erkennen. HUANG ET AL. (2008) nutzt Bayessche Netzwerke zur Interpretation von Fehlersymptomen im Anwendungsfall von Infotainmentsystemen in Fahrzeugen. Die zum Aufbau der Bayesschen Netzwerke benötigten A-priori-Verteilungen (vgl. Abschnitt 2.2.10) werden aus statistischen Daten erhoben, bedingte Wahrscheinlichkeiten ergeben sich aus Expertenbefragungen. Diskutiert werden hierbei Methoden wie die FMEA



oder FTA. Allerdings bleibt ungeklärt, wie die Kopplung des Expertenwissens mit dem Bayesschen Netzwerk methodisch durchgeführt wird (HUANG ET AL. 2008, S. 305). LI & SHI (2007) nutzen Bayessche Netzwerke, um kausale Zusammenhänge zwischen der Produktqualität und Prozessvariablen in einem Walzprozess zu identifizieren. Das Bayessche Netzwerk wird mithilfe von Algorithmen auf Basis von Produktionsdaten aufgebaut. Expertenwissen wird dabei verwendet, um qualitätsrelevante Variablen zu selektieren und den Prozessschritten zuzuordnen. Gleichzeitig wird mithilfe des Expertenwissens eine Dimensionsreduzierung unterstützt, um den Zustandsraum zu verringern (LI & SHI 2007, S. 687). Der von LI & SHI (2007) vorgestellte Ansatz basiert auf einem umfangreichen Datensatz mit über 100.000 Einträgen, weshalb eine Übertragung auf die frühe Phase eines Produktionsanlaufes nur bedingt möglich ist. Es kann zudem nicht nachgewiesen werden, ob die Methodik sich für komplexe verfahrenstechnische oder fertigungstechnische Prozessketten eignet, da in dem beschriebenen Anwendungsfall lediglich zwei Prozessschritte mit insgesamt 22 Variablen betrachtet werden.

### 3.3 Zusammenfassung der Ansätze in der Forschung

Die Ergebnisse der diskutierten Forschungsarbeiten sind in aggregierter Form in Tabelle 3-1 zusammengefasst. Der Erfüllungsgrad der Bewertungskriterien, die in Kapitel 3 definiert wurden, spiegelt sich im Füllgrad der Kreise wieder. Ein leerer Kreis (○) bedeutet, dass ein Kriterium nicht ausreichend untersucht ist, während ein ausgefüllter Kreis (●) die vollständige Untersuchung eines Kriteriums ausdrückt. Die unvollständige Untersuchung eines Kriteriums wird durch den Füllgrad des Kreises (◐◑◒) dargestellt.

In Tabelle 3-1 ist deutlich zu erkennen, dass die Analyse von Ursachen-Wirkzusammenhängen einen zentralen Bestandteil aller vorgestellten Forschungsarbeiten darstellt. Viele der aktuellen Veröffentlichungen stehen zudem im industriellen Kontext der Batteriezellenproduktion. Dies kann mit den in Kapitel 1 beschriebenen Trends in der Elektromobilität begründet werden. In nahezu allen Forschungsarbeiten werden sowohl prozessweise als auch prozessübergreifende Zusammenhänge betrachtet. Es zeichnet sich allerdings ab, dass die Umsetzung eines ganzheitlichen Qualitätsmanagementsystems nicht ausreichend untersucht wurde. Auch kann keine Anwendbarkeit der Konzepte für einen vollständigen Produktionsanlauf nachgewiesen werden. Zudem wird deutlich, dass es eine Differenzierung in experten- und datengetriebene Ansätze gibt.

Tabelle 3-1: Zusammenfassung der relevanten Forschungsansätze.

Bewertungskriterien	SCHÄFER 2003	EICHGRÜN 2003	WESTERMEIER 2016	SCHNELL & REINHART 2016	GROßMANN ET AL. 2013	SCHNELL ET AL. 2019	THIEDE ET AL. 2019	MEYER ET AL. 2019	GRÖGER 2015	RASHIDY 2007	LEE 2001	MCCAUGHT & CHAN 2011	ASMA ET AL. 2014	HUANG ET AL. 2008
Anwendbarkeit in der Batterie-zellenproduktion	☐	☐	●	☐	☐	●	●	●	☐	☐	○	☐	☐	☐
Analyse von Ursachen-Wirkzusammenhängen														
Prozessweise Analyse	☐	●	●	●	●	●	●	●	●	●	●	●	●	●
Prozessübergreifende Analyse	☐	●	●	●	☐	●	●	○	●	☐	●	●	●	●
Expertenbasierte Ansätze	☐	☐	●	●	☐	○	○	☐	○	☐	●	●	○	☐
Datenbasierte Ansätze	☐	○	☐	☐	☐	●	●	●	●	☐	○	☐	●	●
Eignung für komplexe Prozessketten	☐	☐	●	●	☐	☐	☐	○	☐	☐	●	☐	○	☐
Eignung für einen Produktionsanlauf														
Produkt- und Prozess-Generizität	☐	☐	☐	☐	☐	○	☐	○	☐	☐	☐	☐	☐	☐
Skalierbarkeit	○	○	☐	☐	○	☐	☐	○	○	☐	☐	☐	☐	☐
Vollständigkeit des Qualitätsmanagementsystems														
Implementierung von KPIs	○	○	○	☐	○	○	○	○	☐	☐	○	○	☐	○
Fehler-Ursachen-Analyse	☐	☐	☐	☐	☐	☐	☐	○	☐	☐	☐	☐	●	●
Kontinuierliche Qualitätssteigerung	○	○	☐	☐	☐	☐	☐	☐	☐	☐	○	○	☐	☐
Praxistauglichkeit	☐	☐	☐	○	☐	☐	●	☐	☐	☐	○	☐	☐	☐

Die Forschungsarbeiten von SCHÄFER (2003), EICHGRÜN (2003), WESTERMEIER (2016) und SCHNELL & REINHART (2016) lassen sich den expertenbasierten Ansätzen zuordnen. Die Motivation der Arbeiten resultiert aus der Erkenntnis, dass traditionelle Ansätze des Qualitätsmanagements, wie bspw. die FMEA, nicht ausreichend für eine Anwendung in komplexen Prozessketten sind (SCHÄFER 2003, S. 95, WESTERMEIER 2016, S. 1-2, HALFORD ET AL. 2005, GABRIEL ET AL. 2012, S. 4). Dies spiegelt sich insbesondere im Anwendungsfall der Batterie-zellenproduktion wider, in welcher eine hohe Anzahl von Prozessarten, Prozesskettenelementen, Qualitätsmerkmalen und damit zusammenhängenden Ursachen-Wirkzusammenhängen vorliegt. Eine weitere Herausforderung der FMEA liegt darin, diese für eine

Prozessführung zu nutzen (TENG & HO 1996, S. 9). Zudem stützen die genannten Veröffentlichungen sich auf Matrix-basierte Methoden. Jedoch zeichnen sich diese Methoden durch eine geringe Praxistauglichkeit aus und sind nur bedingt für einen vollständigen Anlauf geeignet. Auch weisen die genannten Forschungsarbeiten keinen ganzheitlichen Ansatz eines Qualitätsmanagementsystems auf.

Die Veröffentlichungen von SCHNELL & REINHART (2016), THIEDE ET AL. (2019), MEYER ET AL. (2019), GRÖGER (2015) und RASHIDY (2007) lassen sich den datengetriebenen Methoden zuordnen, welche gemäß des Data-Minings das Ziel verfolgen, Muster aus feldorientierten Daten zu extrahieren (FAYYAD ET AL. 1996). Die Verwendung von Data-Mining stellt insbesondere im Anwendungsfall der Batteriezellenproduktion einen aktuellen Trend dar, um Ursachen-Wirkzusammenhänge fundiert nachzuweisen. Allerdings setzen datengetriebene Ansätze die Verfügbarkeit eines umfangreichen Datensatzes voraus, welcher zu Beginn eines Produktionsanlaufes nicht zwangsläufig sichergestellt werden kann (VMDA 2018, S. 65).

Die Forschungsarbeiten von LEE (2001), MCNAUGHT & CHAN (2011), ASMA ET AL. (2014) und HUANG ET AL. (2008) haben gemeinsam, dass sie methodisch auf Bayessche Netzwerke aufbauen. In allen Forschungsarbeiten konnte nachgewiesen werden, dass Bayessche Netzwerke einen hilfreichen Ansatz darstellen können, um Fehler-Ursachen-Analysen durchzuführen. Bayessche Netzwerke können auf Basis von Expertenwissen oder Daten berechnet werden. Beide Vorgehensweisen zeigen jedoch deutliche Limitierungen. Im Falle der expertenbasierten Ansätze stellt die fehlende methodische Unterstützung bei der Wissensakquisition eine zentrale Limitierung dar. Mit der Anzahl von Ursachen-Wirkzusammenhängen steigt die Größe der zum Aufbau eines Bayesschen Netzwerkes benötigten Wahrscheinlichkeitstabellen exponentiell an (ABRAHAM 2017, S. 100). Dies führt zwangsläufig zu einem hohen Bewertungsaufwand für die Prozessexperten. Des Weiteren stellt das Auftreten von Widersprüchen in der Akquisition von Expertenwissen eine weitere Herausforderung dar, wie bereits von LEE hervorgehoben wurde (LEE 2001, S. 14). Datenbasierte Bayessche Netzwerke hingegen setzen, wie auch das Data-Mining, einen umfangreichen bestehenden Datensatz voraus. Dieser ist in der frühen Phase eines Produktionsanlaufes nicht zwangsläufig vorhanden, weshalb das Kriterium der Eignung für einen Produktionsanlauf nicht ausreichend erfüllt wird. Der wesentliche zeitliche Aufwand für den Aufbau und die Berechnung von komplexen Bayesschen Netzwerken, in welchen eine Vielzahl von Ursachen-Wirkzusammenhängen zu betrachten sind, stellt somit eine wesentliche Limitierung datenbasierter Bayesscher Netzwerke dar (OLIVA ET AL. 2010, S. 503, DIALLO ET AL. 2018, S. 587).

### 3.4 Ableitung des Forschungsbedarfes

Es lässt sich ableiten, dass sowohl durch expertenbasierte als auch datenbasierte Ansätze eine Identifizierung von Ursachen-Wirkzusammenhängen unterstützt werden kann. Das Potenzial, gleichzeitig auf experten- und datenbasierte Ansätze zuzugreifen, wird jedoch in keiner der diskutierten Forschungsarbeiten ausgeschöpft. Zwar wird im standardisierten Prozessmodell für Data-Mining, CRIPS-DM, das Expertenwissen im Schritt des „Business Understandings“ berücksichtigt, allerdings gibt es im weiteren Analyseprozess keine spezifizierten Interaktionen zwischen der Datenanalyse und dem Experten. Eine isolierte Betrachtung beider Ansätze ist bedingt zielführend. Expertengetriebene Ansätze, wie bspw. in WESTERMEIER (2016) dargestellt, bringen nachweislich einen Mehrwert bei der Anwendung in einer frühen Phase eines Produktionsanlaufes, in welcher keine Produktionsdaten zum Quantifizieren von Ursachen-Wirkzusammenhängen vorhanden sind. Eine Bewertung durch Experten ist allerdings immer mit einer Unsicherheit behaftet (WESTERMEIER 2016, S. 3). Ab Beginn einer Datenaufzeichnung und unter der Prämisse einer hohen Datenqualität, lassen sich datenbasierte Ansätze zur Identifizierung von Ursachen-Wirkzusammenhängen verwenden (SCHENDERA 2007, S. 6). Eine Herausforderung stellt hierbei allerdings die Messbarkeit von Prozess- und Produkteigenschaften dar. Die hohe Anzahl an Prozesskettenelementen erfordert einen umfangreichen und kostenintensiven Ausbau von Sensoren zur Ermittlung der Eigenschaften sowie eine ganzheitliche IT-Infrastruktur zur effizienten Datenanbindung, -verknüpfung, und -sicherung (VMDA 2018, S. 73, GRÖGER 2015, S. 71). Zudem lassen sich insbesondere in der Batteriezellenproduktion Produkteigenschaften teilweise nur zerstörend oder mit hohem Aufwand messen (WESTERMEIER 2016, S. 86). Der Untersuchungsraum für Datenanalysemethoden limitiert sich somit auf uneingeschränkt messbare Prozesskettenelemente. Für die ganzheitliche Untersuchung aller Prozesskettenelemente einer Batteriezellenproduktion ist die Verwendung von experten- und datenbasierten Ansätzen somit zwingend erforderlich, um eine Qualitätssicherung während des vollständigen Anlaufes bis hin zu einer Serienproduktion zu unterstützen. Ein wesentliches Forschungsdefizit liegt somit in der Verknüpfung der beiden genannten Domänen, um alle qualitätsrelevanten Ursachen-Wirkzusammenhänge zu identifizieren. Darüber hinaus muss mithilfe einer synergetischen Verknüpfung der beiden Domänen das Expertenwissen genutzt werden, um die Datenanalyse zu unterstützen. Umgekehrt müssen die Datenanalysen verwendet werden, um das Wissen der Experten zu schärfen. Eine solche **synergetische Verknüpfung experten- und datenbasierter Ansätze** wurde in keiner der bisherigen Forschungsarbeiten betrachtet.

Im Bereich der Datenanalysen ist ein weiterer großer Forschungsbedarf erkennbar, da nach CAO & ZHANG (2008) die Ergebnisse vieler Data-Mining-Prozesse für Anwender häufig nicht

verwertbar sind. Ohne die Unterstützung durch Experten repräsentieren Data-Mining-Vorgehen häufig einen rein datengetriebenen Trial-and-Error-Prozess, welcher keinen Mehrwert für reale Anwendungen bietet (CAO & ZHANG 2008, S. 49, CAO 2010, S. 41). Dies kann bspw. auf die in Abschnitt 2.2.4 beschriebene Existenz von Scheinkorrelationen zurückgeführt werden (KOSFELD ET AL. 2016). Die Erarbeitung eines durch **Experten gestützten Konzeptes zur Datenanalyse** stellt ein weiteres zentrales Forschungsdefizit dar (KORNAS ET AL. 2019A).

Das letzte Forschungsdefizit adressiert die Erarbeitung eines ganzheitlichen Qualitätsmanagementsystems, in welchem KPI-Systeme, Methoden einer Fehlursachenanalyse sowie ein systematischer Ansatz zur kontinuierlichen Qualitätssteigerung implementiert sind. Aus dem Stand der Forschung lässt sich ableiten, dass es derzeit kein einheitliches KPI-System gibt, welches für einen vollständigen Produktionsanlauf anwendbar ist. Bayessche Netzwerke stellen zwar eine vielversprechende Methode für die Fehler-Ursachen-Analyse dar, es zeigt sich allerdings, dass ein Forschungsansatz entwickelt werden muss, um diese auch für komplexe Prozessketten anwenden zu können. Dies impliziert einerseits eine Entwicklung von geeigneten Methoden zur Wissensakquisition sowie zum Aufbau von Wahrscheinlichkeitstabellen. Andererseits muss gewährleistet werden, dass bei einer hohen Anzahl von Ursachen-Wirkzusammenhängen auch eine anwendergerechte Berechnungszeit in der Fehler-Ursachen-Analyse nachgewiesen werden kann (ABRAHAM 2017, S. 100). Unter dem Aspekt eines Produktionsanlaufes stellt die Entwicklung eines **ganzheitlichen Qualitätsmanagementkonzeptes**, in welchem ein systematischer Ansatz zur Prozessführung, die **Berechnung von KPIs** sowie eine **Fehler-Ursachen-Analyse** methodisch in ein Gesamtsystem integriert sind, somit eine weitere Forschungslücke dar.

## 4 Konzept eines Qualitätsmanagementsystems für die Produktion von Batteriezellen

Der Stand der Forschung hat aufgezeigt, dass es für eine konsequente Reduzierung des Ausschusses in komplexen Prozessketten an einem ganzheitlichen Qualitätsmanagementsystem mangelt. Für die systematische Entwicklung eines solchen Qualitätsmanagementsystems werden in Unterkapitel 4.1 Einzelziele (Z) definiert. Den Einzelzielen lassen sich Anforderungen (A) zuordnen, welche festgelegten oder vorausgesetzten Erfordernissen entsprechen. Diese bilden die Grundlage des in Unterkapitel 4.2 beschriebenen Qualitätsmanagementkonzepts einer Batteriezellenproduktion. Das Qualitätsmanagementkonzept basiert auf zentralen Lösungsbausteinen, welche in den Unterkapiteln 4.3, 4.4 und 4.5. diskutiert werden. Die Validierung des Gesamtkonzepts und die damit verbundene softwaretechnische Umsetzung beschreibt Unterkapitel 4.6.

### 4.1 Ziele und Anforderungen

Wie Abbildung 25 entnommen werden kann, liegt das Ziel der vorliegenden Forschungsarbeit in der Entwicklung eines Qualitätsmanagementsystems. Dieses soll den Anwendern, die durch Anlagenbediener, Technologen oder Entwickler repräsentiert werden, als Entscheidungsunterstützung dienen, um den Ausschuss in der Anlaufphase und im Serienbetrieb einer Batteriezellenproduktion zu reduzieren.

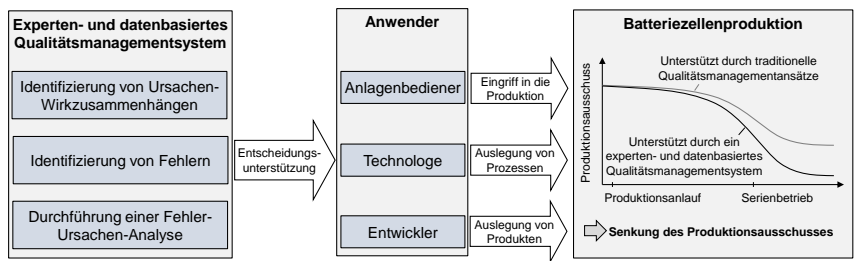


Abbildung 25: Grobkonzept zur Ausschussreduzierung in einer Batteriezellenproduktion.

Aus dem Stand der Forschung lässt sich ableiten, dass die Identifizierung von Ursachen-Wirkzusammenhängen die Voraussetzung einer zielorientierten Ausschussreduzierung darstellt,

da sie ein Aufzeigen direkter und prozessübergreifender Einflüsse auf die Produktqualität ermöglicht. Ursachen-Wirkzusammenhänge lassen sich mithilfe experten- und datenbasierter Ansätze ermitteln. Es kann insbesondere durch eine synergetische Verknüpfung dieser beiden Domänen ein Potenzial gehoben werden. So kann das Expertenwissen genutzt werden, um die Datenanalyse zu unterstützen, und umgekehrt kann die Datenanalyse verwendet werden, um das Wissen der Experten zu schärfen. In Unterkapitel 3.4 wird zudem abgeleitet, dass für einen ganzheitlichen Qualitätsmanagementansatz eine Methode zur Fehleridentifizierung als auch zur Fehler-Ursachen-Analyse vorliegen muss, um eine systematische und kontinuierliche Qualitätsverbesserung zu erzielen.

Vor dem Hintergrund der in der Batteriezellenproduktion vorliegenden Komplexitätsmerkmale (vgl. Unterkapitel 1.1) liegen die Ziele der Forschungsarbeit somit in der Entwicklung einer Methode zur:

- Z<sub>1</sub>:** Identifizierung von Ursachen-Wirkzusammenhängen,
- Z<sub>2</sub>:** Identifizierung von Fehlern und Produktionssauschüssen,
- Z<sub>3</sub>:** Durchführung einer Fehler-Ursachen-Analyse,
- Z<sub>4</sub>:** Integration der aus den in Z<sub>1</sub>-Z<sub>3</sub> entwickelten zentralen Lösungsbausteinen in ein Qualitätsmanagementkonzept zur zielorientierten Ausschussreduzierung

Den spezifizierten Zielen werden nachfolgend Anforderungen zugeordnet. Die Anforderungen repräsentieren grundlegende Voraussetzungen und werden für eine kritische Gegenüberstellung der entwickelten Methoden und deren Implementierung verwendet.

#### **Z<sub>1</sub>: Identifizierung von Ursachen-Wirkzusammenhängen**

Wie in Kapitel 1 und Kapitel 3 gezeigt, stellt die Identifizierung von Ursachen-Wirkzusammenhängen die Voraussetzung einer qualitätsorientierten Optimierung in der Batteriezellenproduktion dar. Die hohe Komplexität und Anzahl an Prozessarten führt dazu, dass einzelne Prozessschritte und dazugehörige Produktionsanlagen von speziell ausgebildeten Experten betreut werden müssen (KORNAS ET AL. 2019A, S. 383). Die Bewertung von insbesondere prozessübergreifenden Zusammenhängen stellt die Experten deshalb vor große Herausforderungen. Darüber hinaus ist der Mensch kognitiv nur in der Lage, ein System aus bis zu vier Variablen gleichzeitig zu verarbeiten (HALFORD ET AL. 2005, S. 71). Gefordert wird somit eine:

- **A<sub>11</sub>:** *methodische Unterstützung in der expertenbasierten Erfassung von Ursachen-Wirkzusammenhängen.*
- **A<sub>12</sub>:** *Berücksichtigung unterschiedlicher Expertenmeinungen, um eine vollständige Identifizierung von Ursachen-Wirkzusammenhängen zu erzielen.*

- **A<sub>13</sub>:** *Eignung für komplexe Prozessketten*, sodass prozessweise und prozessübergreifende Ursachen-Wirkzusammenhänge identifiziert werden können. Dies impliziert auch die Berücksichtigung von direkten, indirekten, einfachen oder mehrfachen Ursachen-Wirkzusammenhängen.

Um die von Experten bewerteten Ursachen-Wirkzusammenhänge fundiert nachzuweisen, sind im Weiteren Methoden der Datenanalyse zu integrieren. Im Detail wird gefordert, dass

- **A<sub>14</sub>:** *feldorientierte Untersuchungen* berücksichtigt werden, um im Gegensatz zu labororientierten Ansätzen auch Daten aus einem realen System analysieren zu können (KUBLER ET AL. 2017, S. 1).
- **A<sub>15</sub>:** ein durch *Experten gestützter Prozess der Datenanalyse* vorliegt, um für den Anwender eines Data-Mining-Prozesses verwertbare Ergebnisse zu erzielen (vgl. CAO & ZHANG 2008, S. 49). Dieser impliziert die Nachvollziehbarkeit der Data-Analytics-Modelle und Interpretierbarkeit der Ergebnisse (CAO 2010, S. 4-5).

Die synergetische Verwendung aus experten- und datengetriebenen Methoden bildet ein grundlegendes Alleinstellungsmerkmal dieser Forschungsarbeit. Gefordert wird deshalb, dass

- **A<sub>16</sub>:** ein *komplementärer Erkenntnisgewinn* vorliegt, sodass experten- als auch datengetriebene Ansätze methodisch zusammengeführt werden können.
- **A<sub>17</sub>:** eine *Integration der Fertigungsebene und Fertigungsleitebene bis hin zum Entwicklungspersonal berücksichtigt* wird, sodass eine ganzheitliche Betrachtung der Produktion gewährleisten werden kann.
- **A<sub>18</sub>:** eine *Skalierbarkeit in der Identifizierung von Ursachen-Wirkzusammenhängen* vorliegt, sodass eine Anwendung des Qualitätsmanagementsystems ausgehend vom Produktionsanlauf, zu dem nur eine kleine Wissensbasis zur Verfügung steht, bis hin zur Serienproduktion gewährleisten werden kann.

## **Z<sub>2</sub>: Identifizierung von Fehlern und Produktionssauschüssen**

Die Identifizierung von Fehlern und Produktionssauschüssen bildet eine Voraussetzung, damit der Anwender seiner Aufgabe als regelndes Element innerhalb des Qualitätsregelkreises nachkommen kann. Aufgrund der in der Batteriezellenproduktion vorliegenden Ursachen-Wirkzusammenhänge können Fehler isoliert oder im Zusammenwirken von mehreren Prozesskettenelementen entstehen. Gefordert wird deshalb:

- **A<sub>21</sub>:** eine *Identifizierung komplexer Fehlerbilder*.
- **A<sub>22</sub>:** Werkzeuge zur *Darstellung komplexer Fehlerbilder*.



Für eine Anwendbarkeit des Qualitätsmanagementsystems innerhalb des vollständigen Produktionsanlaufes einer Batteriezellenproduktion ist darüber hinaus zu berücksichtigen, dass:

- **A<sub>23</sub>:** eine *produkt- und prozessgenerische Anwendbarkeit* vorliegt, sodass unterschiedliche Produkte und Prozesse sowie Qualitätsmerkmale verglichen werden können. Die Anforderungen der Generizität resultieren insbesondere aus der Prototypenproduktion, in welcher noch Entscheidungen über Design, Materialien und Produktionsparameter zu treffen sind (KWADE ET AL. 2018, S. 297).
- **A<sub>24</sub>:** ein *einheitliches Konzept zur Fehleridentifizierung für unterschiedliche Losgrößen* vorliegt, da sich die einzelnen Phasen eines Produktionsanlaufes durch unterschiedliche Produktionsstückzahlen auszeichnen (vgl. Abschnitt 2.2.1).

### **Z<sub>3</sub>: Durchführung einer Fehler-Ursachen-Analyse**

Die Fehler-Ursachen-Analyse (im Englischen Root Cause Analysis, kurz RCA) bezeichnet einen Prozess, um Ursachen von Ereignissen, welche die Qualität oder Zuverlässigkeit beeinflussen, zu identifizieren (ROMEIKE 2017, S. 100). Während die Fehleridentifizierung (Z<sub>2</sub>) hilft, den Fehler als solchen zu ermitteln, verfolgt die Fehler-Ursachen-Analyse das Ziel zu erkennen, warum der Fehler aufgetreten ist. Die Fehler-Ursachen-Analyse bildet die Grundlage für eine Prozessoptimierung und kann somit als ein Kernbaustein des Qualitätsmanagements betrachtet werden. Da nach LINß Fehler-Ursachen-Analysen allerdings häufig mit hohem Zeitaufwand verbunden sind (LINß 2013, S. 217), wird gefordert, dass:

- **A<sub>31</sub>:** eine *Praxistauglichkeit* vorliegt, welche impliziert, dass eine einfache sowie zeit- und ressourceneffiziente Durchführbarkeit gegeben ist.

Die Fehler-Ursachen-Analyse ist im Kontext des Qualitätsregelkreises als eine zentrale Entscheidungshilfe zu betrachten und soll dazu dienen, das Situationsbewusstsein zu schärfen. Hieraus resultieren die Forderungen, dass:

- **A<sub>32</sub>:** als Ergebnis der Fehler-Ursachen-Analyse eine *Priorisierung von Handlungsmaßnahmen* vorliegt.
- **A<sub>33</sub>:** eine *Nachvollziehbarkeit der Ergebnisse* gegeben ist. Diese kann durch geeignete Visualisierungen unterstützt werden, wie bspw. eine grafische Darstellung von Kausalzusammenhängen.

#### **Z<sub>4</sub>: Integration in ein Qualitätsmanagementkonzept zur zielorientierten Ausschussreduzierung**

Da erst auf Grundlage der identifizierten Ursachen-Wirkzusammenhänge ( $Z_1$ ) und Fehlerbilder ( $Z_2$ ) eine zielorientierte Fehler-Ursachen-Analyse ( $Z_3$ ) erfolgen kann, wird im Sinne eines ganzheitlichen Qualitätsmanagementkonzepts gefordert, dass:

- **A<sub>41</sub>:** die Ziele  $Z_1$ - $Z_3$  *methodisch Verknüpft* werden müssen.

Vor dem Hintergrund einer Anwendung vom vollständigen Produktionsanlauf bis hin zum Serienbetrieb muss das Qualitätsmanagementsystem:

- **A<sub>42</sub>:** das Ziel einer *kontinuierlichen Verbesserung der Produkte und Prozesse* verfolgen.
- **A<sub>43</sub>:** experten- und datenbasiertes Wissen über Ursachen-Wirkzusammenhänge *strukturiert und aktualisierbar in einer Wissensdatenbank* hinterlegen.

Die Anwender des Qualitätsmanagementsystems sind Mitarbeiter der Fertigungsebene und Fertigungsleitebene bis hin zum Entwicklungspersonal. Da nach CLEFF nur verstandene und damit akzeptierte Ergebnisse eine Entscheidungsgrundlage für Handlungsträger bilden, wird gefordert, dass (CLEFF 2015, S. 13):

- **A<sub>44</sub>:** eine *Praxistauglichkeit des Gesamtkonzepts* vorliegt. Dabei muss die Verknüpfung der zu entwickelnden zentralen Lösungsbausteine für den Anwender nachvollziehbar sein. Das Qualitätsmanagementsystem muss sich durch einen systematischen Ablauf und eine einfache Durchführbarkeit auszeichnen sowie zeit- und ressourceneffizient umsetzbar sein.
- **A<sub>45</sub>:** eine *Nachvollziehbarkeit des Gesamtkonzepts* berücksichtigt wird.

Nach GRÖGER (2015) basieren traditionelle Qualitätsmanagementansätze in Produktionen meist auf deskriptiven Verfahren und finden somit reaktiv, also nach Eintreten eines Ereignisses, statt. Diese Form der Ansätze zur Prozesskettenführung ist vergangenheitsorientiert. Um die Folgen einer laufenden Prozessinstanz bspw. auf Basis aktueller und historischer Daten zu bewerten, wird gefordert:

- **A<sub>46</sub>:** *proaktive Ansätze einer Prozesskettenführung* zu implementieren. Diese ermöglichen es, die Entstehung von Fehlern zu vermeiden oder die Auswirkungen bereits aufgetretener Fehler zu minimieren. (GRÖGER 2015, S. 8)

## 4.2 Konzeptentwicklung

Die in Unterkapitel 4.1 definierten Ziele sind angelehnt an eine Qualitätssteuerung, welche als zentrales Element des Qualitätsmanagements die vorbeugende, überwachende und korrigierende Tätigkeit umfasst, anforderungsgerechte Produkte herzustellen (GEITNER 2013, S. 409). Für eine zielorientierte Unterstützung dieser Tätigkeit können, in Analogie zur Regelungstechnik, sogenannte Qualitätsregelkreise hinzugezogen werden (vgl. Unterkapitel 2.2). Diese lassen sich definieren als „[...] abgeschlossene technologisch-organisatorische Wirkungsabläufe in einem Prozess zur Schaffung eines Qualitätsproduktes [...]“ (LINß 2013, S. 20).

Wie in Abbildung 26 verdeutlicht, dienen in der klassischen Regelungstechnik Regelkreise einer Optimierung technischer Prozesse (HEINRICH 2019, S. 128).




Abbildung 26: Konzept einer Regelung nach DIN 55350-11.

Sie zeichnen sich durch einen geschlossenen Wirkungsablauf aus, bei welchem die Regelgröße im Wirkungsweg des Regelkreises beeinflusst und zurückgeführt wird (vgl. SCHNEIDER & HEINRICH 2017, S. 4). Die vorliegende Forschungsarbeit lehnt sich an die Grundidee eines Qualitätsregelkreises an. Wie in Tabelle 4-1 zu entnehmen ist, lassen sich die Bestandteile eines technischen Regelkreises eindeutig auf einen Qualitätsregelkreis für fertigungstechnische und verfahrenstechnische Prozessketten, wie eine Batteriezellenproduktion übertragen.

Tabelle 4-1: Elemente zur Übertragung eines technischen Regelkreises auf einen Qualitätsregelkreis der Batteriezellenproduktion (in Anlehnung an KLOSTERMANN 2008, S. 53).

Elemente eines technischen Regelkreises	Beschreibung	Übertragung auf einen Qualitätsregelkreis	Beschreibung
Führungsgröße	Eine von der Regelung nicht beeinflusste Größe, die dem Regelkreis von außen zugeführt wird und welche der Ausgangsgröße der Regelung in vorgegebener Abhängigkeit folgen soll.	Zielgröße	Messbare Erfolgsgröße, die sich aus dem übergeordneten Ziel des Qualitätsmanagementsystems ableitet und durch den Produktionsausschuss repräsentiert wird.
Regelstrecke	Aufgabengemäß zu beeinflussender Teil des Qualitätsmanagementsystems.	Prozesskette	Prozesskette zur Herstellung von Batteriezellen.
Regeleinrichtung	Derjenige Teil des Wirkungsweges, der die aufgabengemäße Beeinflussung der Regelstrecke über das Stellglied bewirkt.	Anwender	Diejenige Person, die ein Hilfs- oder Arbeitsmittel zur Beeinflussung der Produktion besitzt. Konkret sind dies Anlagenbediener, Technologen oder Entwickler.
Stellgröße	Ausgangsgröße der Regeleinrichtung und Eingangsgröße der Regelstrecke. Sie überträgt die steuernde Wirkung der Einrichtung auf die Strecke.	Qualitätsmaßnahme	Eine durch den Anwender umzusetzende Optimierungsmaßnahme zur Erreichung der Zielgröße. Erfolgt über den Eingriff in die Produktion sowie eine Produkt- und Prozessauslegung.
Regelgröße	Größe der Regelstrecke, die zum Zwecke des Regels erfasst und über die Messeinrichtung der Regeleinrichtung zugeführt wird.	Qualitätskenngröße	Subjektiv oder objektiv messbare Erfolgsgröße des Produktes (bspw. Gewicht oder Kapazität einer Batteriezelle), welches es zu optimieren gilt.
Störgröße	Von außen wirkende Größe, die eine unbeabsichtigte Beeinflussung in der Regelung bewirkt.	Störgröße	Durch bspw. Mensch, Maschine oder Material verursachte, unbeabsichtigte Einflussgröße.

Abgeleitet aus den spezifizierten Zielen und Anforderungen aus Unterkapitel 4.1 sowie den hergeleiteten Elementen eines Qualitätsregelkreis nach Tabelle 4-1 ergibt sich das in Abbildung 27 dargestellte Konzeptbild der vorliegenden Forschungsarbeit, welches nachfolgend im Detail diskutiert wird.

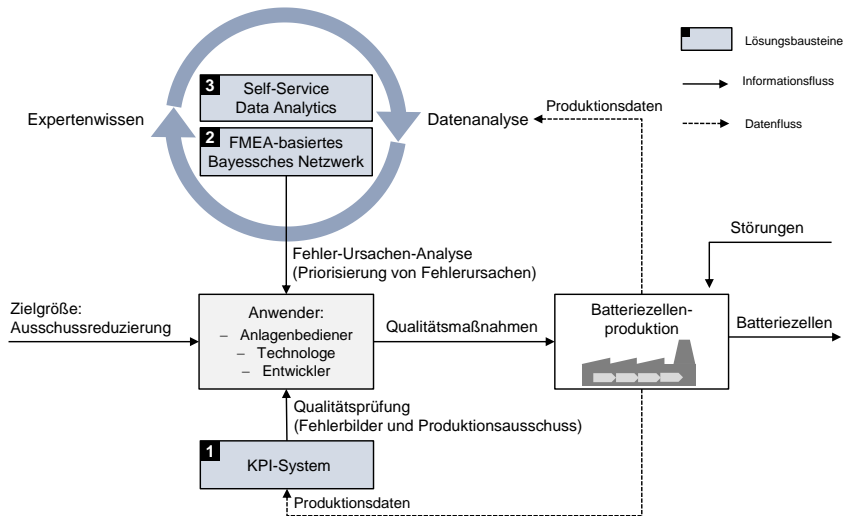


Abbildung 27: Konzeptbild eines experten- und datenbasierten Qualitätsmanagementsystems einer Batteriezellenproduktion.

Das übergeordnete Ziel des Konzepts liegt in der **Ausschussreduzierung**, da sie den wesentlichen Hebel zur Senkung der Kosten und produktionsbedingter CO<sub>2</sub>-Emissionen einer Batteriezellenproduktion bildet. Eine Ausschussreduzierung, erfolgt durch die von Anwendern induzierten **Qualitätsmaßnahmen**. **Anwender** werden dabei als diejenige Person definiert, die durch ausgewählte Hilfsmittel die Möglichkeit besitzen, die Produktion von Batteriezellen qualitativ zu beeinflussen. Sie werden durch Anlagenbediener, Technologen oder Entwickler repräsentiert. So können produktionsseitige Anpassungen, wie bspw. Veränderungen von Prozessparametern über die Anlagenbediener oder Technologen ausgeführt werden. Produktseitig Qualitätsmaßnahmen, wie bspw. die Veränderungen von Geometrien sind durch Entwickler durchzuführen. Aufgrund der in der Batteriezellenproduktion vorliegenden Komplexitätsmerkmale, welche sich unter anderem durch die unterschiedlichen Prozessarten sowie die hohe Anzahl an Prozessschritten, Prozesskettenelementen und Ursachen-Wirkzusammenhängen auszeichnen (vgl. Unterkapitel 1.1), bedarf es einer Entscheidungsunterstützung, um geeignete Qualitätsmaßnahmen zu identifizieren. Bestandteil der Entscheidungsunterstützung ist eine **Qualitätsprüfung** zur Ermittlung von Fehlerbildern sowie eine **Fehler-Ursachen-Analyse**, die ausgehend von den identifizierten Fehlerbildern eine Priorisierung von Fehlerursachen ermöglicht. Die Qualitätsprüfung und Fehler-Ursachen-Analyse basieren auf drei zentralen Lösungsbausteinen.

### **Lösungsbaustein 1: KPI-System**

Das KPI-System dient der eindeutigen Identifizierung von Fehlerbilder auf Basis von Produktionsdaten. Zudem wird der Produktionsausschuss errechnet, da dieser das übergeordnete Ziel des Qualitätsmanagementsystems darstellt und somit eine messbare Erfolgsgröße bildet. Die Entwicklung des KPI-Systems wird in Unterkapitel 4.3 beschrieben.

### **Lösungsbaustein 2: FMEA-basiertes Bayessches Netzwerk**

Bayessche Netzwerke können gemäß dem Stand der Forschung verwendet werden, um bedingte Wahrscheinlichkeiten von Ereignissen zu berechnen. In Abschnitt 3.2.3 wurde gezeigt, dass sie einen geeigneten Ansatz zur Durchführung einer Fehler-Ursachen-Analyse repräsentieren. Das FMEA-basierte Bayessches Netzwerk (nachfolgend kurz „Bayessches Netzwerk“ genannt) ist einerseits als expertenbasierter Ansatz zur Identifizierung von Ursachen-Wirkzusammenhänge zu betrachten. Es stellt darüber hinaus für die Anwender eine Entscheidungsunterstützung dar, um ausgehend von den im KPI-System identifizierten Fehlerbildern eine Priorisierung von Fehlerursachen zu errechnen. Die Entwicklung des Bayesschen Netzwerkes wird in Unterkapitel 4.4 beschrieben.

### **Lösungsbaustein 3: Self-Service Data Analytics**

Mithilfe der Self-Service Data Analytics werden Ursachen-Wirkzusammenhänge auf Basis einer Datenanalyse fundiert nachgewiesen. Zusammen mit dem Bayesschen Netzwerk wird dabei ein synergetischer Ansatz verfolgt, in welchem ein Potenzial durch die Verknüpfung von experten- und datenbasierten Methoden gehoben werden soll. Dabei kann das Expertenwissen des Bayesschen Netzwerkes genutzt werden, um die Datenanalyse zu unterstützen und umgekehrt verfolgt die Datenanalyse das Ziel, das Expertenwissen zu schärfen. Eine Beschreibung der Self-Service Data Analytics und deren methodischen Verknüpfung mit dem Bayesschen Netzwerk erfolgt in Unterkapitel 4.5.

Um eine kontinuierliche Produkt- und Prozessoptimierung während eines vollständigen Produktionsanlaufes zu erzielen, erfolgt abschließend in Unterkapitel 4.6 die methodische Verknüpfung der drei genannten Lösungsbausteine zu einem Gesamtsystem.

### 4.3 KPI-System

Damit der Anwender, wie in Abbildung 28 dargestellt, seiner Aufgabe als regelndes Element innerhalb des Qualitätsregelkreises nachkommen kann, bedarf es einer Methode zur eindeutigen Identifizierung von Fehlerbildern und Produktionsausschüssen.

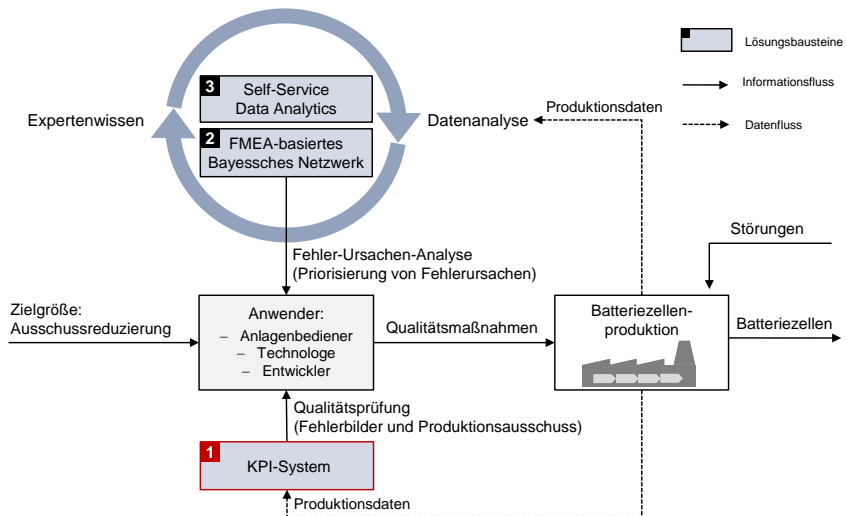


Abbildung 28: Qualitätsmanagementsystems einer Batteriezellenproduktion mit Hervorhebung des KPI-Systems.

Wie in der Arbeit von SCHNELL & REINHART beschrieben, können im Anwendungsfall der Batteriezellenproduktion je nach Prozesskettenauslegung, Zugänglichkeit, Messbarkeit und Messaufwand unterschiedliche Möglichkeiten zur Qualitätsprüfung vorliegen (SCHNELL & REINHART 2016, S. 571):

- Zerstörende oder nicht-zerstörende Prüfung
- In-Line- oder Off-Line-Prüfung
- Stichprobenweise oder 100% Prüfumfang

Eine Qualitätsprüfung kann dabei mit subjektiven oder objektiven Prüfmethode(n) erfolgen (STEVEN 2007, S. 166). Zu den subjektiven Prüfmethode(n) lassen sich Sicht- oder Tastprüfungen zuordnen (WILHELM 2006, S. 65). Diese sind insbesondere zu Beginn eines Produktionsanlaufes relevant, in welchem Eigenschaften von Prozesskettenelementen unter Umständen noch

nicht quantifiziert werden können. Objektive Prüfmethode lassen sich in Messen und Lehren unterteilt. Während beim Messen die Merkmale quantitativ mit einer Einheit beurteilt werden, erfolgt beim Lehren eine Überprüfung, ob Eigenschaften zwischen zwei vorgegebenen Grenzen liegen (LINß 2013, S. 40).

KPIs stellen als Bestandteil objektiver Prüfmethode eine tragende Säule eines Qualitätsregelkreises dar, da sie die Grundlage zum Steuern eines Prozesses schaffen (RAU ET AL. 2012, S. 171). Die Auslegung eines KPI-Systems muss jedoch den Anforderungen an den Anlauf einer Batteriezellenproduktion gerecht werden. Da insbesondere in der Prototypenphase noch Entscheidungen über Design, Materialien und Produktionsparameter zu treffen sind, stellt die Vergleichbarkeit von Produkten, Maschinen und Prozessen eine wesentliche Anforderung an die zu erarbeitende Methodik dar. Des Weiteren müssen die unterschiedlichen Losgrößen in den einzelnen Phasen eines Produktionsanlaufes berücksichtigt werden. Während die Produktion im Labormaßstab oder der Prototypenaufbau einer Batteriezellenfertigung durch kleine Stückzahlen charakterisiert ist, zielt eine Pilotlinie darauf ab, die Prozessfähigkeit eines spezifizierten Zelldesigns mithilfe größerer Stückzahlen nachzuweisen. Es wird gefordert, dass sich das KPI-System für diese unterschiedlichen Losgrößen skalieren lässt. (KORNAS ET AL. 2019B, KWADÉ ET AL. 2018, S. 297)

Aus den beschriebenen Anforderungen leiten sich das in Abbildung 29 dargestellte Konzeptbild eines KPI-Systems sowie die darin enthaltene Strukturierung des vorliegenden Unterkapitels ab.

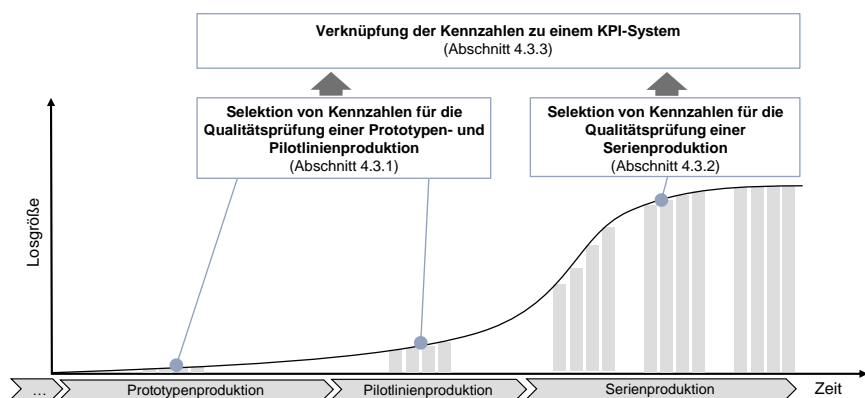


Abbildung 29: Konzeptbild des KPI-Systems für die Batteriezellenproduktion.



#### 4.3.1 *Selektion von Kennzahlen für die Qualitätsprüfung einer Prototypen- und Pilotlinienproduktion*

Nach industriellem Standard lässt sich die Produkt- und Prozessqualität durch unterschiedliche Kenngrößen beschreiben. Eine Übersicht etablierter Berechnungsmöglichkeiten ist Tabelle 8-1 im Anhang zu entnehmen. Dabei wird ersichtlich, dass zur Formulierung von Qualitätskennzahlen oftmals eine Gegenüberstellung von Anforderungen und Vorgaben verwendet wird. So können einfache Quotienten gebildet werden, um qualitätsrelevante Aussagen zu treffen (LINß 2013, S. 457). Fähigkeitsindizes stellen etablierte Kennzahlen dar, um statistisch nachzuweisen, dass ein Fertigungsprozess die Produkte mit geforderter Qualität herstellen kann (ESCHEY 2013, S. 23). Nach LINß lassen sich in Bezug auf einen Produktionsanlauf folgende drei Phasen einer Fähigkeitsuntersuchung identifizieren (LINß 2013, S. 446):

- Die Maschinenfähigkeitsuntersuchung bildet die erste Phase und ist als Kurzzeittest anzuwenden, um die durch Maschinen verursachten Merkmalsstreuungen zu bewerten. Eine Maschinenfähigkeitsuntersuchung wird während der Abnahme neuer Anlagen durchgeführt.
- Darauf aufbauend wird eine vorläufige Prozessfähigkeitsuntersuchung durchgeführt. Sie dient einer Beurteilung der Prozessfähigkeit vor einem Serienanlauf.
- Mithilfe der Langzeit-Prozessfähigkeitsuntersuchung soll der Nachweis erbracht werden, dass auch über einen längeren Produktionszeitraum die Qualitätsanforderungen erfüllt werden können.

Die vorläufige und Langzeit-Prozessfähigkeitsuntersuchung bilden den Bezugsrahmen der nachfolgenden Methodenentwicklung. Aufgrund einer vergleichbaren Betrachtungsweise sowie identischer Berechnungsvorschriften werden beide Ansätze zusammengefasst und als Prozessfähigkeitsuntersuchung bezeichnet (vgl. LINß 2013, Tabelle 13.11). Der Vorteil in der Verwendung von Prozessfähigkeitsindizes zum Aufbau eines KPI-Systems liegt in einer für den Anwender leicht nachvollziehbaren Beurteilung von Qualität. Es gibt, wie Tabelle 8-2 zu entnehmen, darüber hinaus einen direkten Zusammenhang mit dem Produktionsausschuss. So haben bspw. Prozesse mit einer Prozessfähigkeit von  $c_{pk} = 1,33$  eine Fehlerfreiheit von 99,99366%. Dies ermöglicht es Qualitätsniveaus auch aus wirtschaftlicher Perspektive zu bewerten. Zudem bilden Prozessfähigkeitsindizes eine konsistente und einheitliche Basis, in welcher Bezug auf Produkte oder Maschinen genommen werden kann (VMDA 66412-1, S. 34). Dies gewährleistet eine Anwendbarkeit auf unterschiedliche Produkt- und Prozesssysteme einer Batteriezellenproduktion und fördert eine generische Auslegung des KPI-Systems.

Es lässt sich zusammenfassen, dass Prozessfähigkeitsindizes eine geeignete Methode der Qualitätsbewertung darstellen und somit nachfolgend im Detail diskutiert werden.

Nach KORNAS ET AL. können unterschiedliche Prozessfähigkeitsindizes für die Qualitätsbewertung einer Batteriezellenproduktion hinzugezogen werden (KORNAS ET AL. 2019B, S. 78). Univariate Prozessfähigkeitsindizes dienen der isolierten Betrachtung einzelner Eigenschaften von Prozesskettenelementen. Auf Basis von multivariaten Prozessfähigkeitsuntersuchungen können gleichzeitig mehrere Eigenschaften bewertet werden.

Der kritische Prozessfähigkeitsindex  $C_{pk}$  repräsentiert eine etablierte, univariate Prozessuntersuchung (vgl. Abschnitt 2.2.8). Er spiegelt dabei ein diskretes Qualitätsverständnis wider, in welchem bewertet wird, ob sich Eigenschaften von Prozesskettenelementen innerhalb definierter Spezifikationen befinden oder nicht. Die Anwendbarkeit dieser Kennzahl im Bereich der Batteriezellenproduktion soll mithilfe von Abbildung 30 verdeutlicht werden. Die in einer Batteriezelle verbaute Elektrodenlänge stellt demnach ein mithilfe von Toleranzbereichen (USG, OSG) diskret zu bewertendes Prozesskettenelement dar (KORNAS ET AL. 2019B, S. 79). Dies resultiert daraus, dass die Elektrodenlänge im Falle prismatischer Batteriezellen durch den geometrischen Bauraum des Zellgehäuses limitiert und daher in der Produktspezifikation eindeutig beschrieben ist.




Abbildung 30: Anwendung des kritischen Prozessfähigkeitsindex  $C_{pk}$  am Beispiel der Elektrodenlänge in Anlehnung an LINß 2013, S. 447.

Im Gegensatz zum  $C_{pk}$  spiegelt der totale kritische Prozessfähigkeitsindex  $C_{pmk}$  ebenfalls als univariater Ansatz, ein kontinuierliches Qualitätsverständnis wider (vgl. Abschnitt 2.2.8). Durch Verwendung des totalen kritischen Prozessfähigkeitsindex  $C_{pmk}$  werden Qualitätsverluste be-

reits bei einer Zielwertabweichung und nicht erst beim Überschreiten der spezifizierten Toleranzen berücksichtigt. Ein aus der Batteriezellenproduktion abgeleitetes Beispiel stellt die Bewertung der eingebrachten Elektrolytmenge pro Zelle dar (vgl. Abbildung 31).




Abbildung 31: Anwendung eines totalen kritischen Prozessfähigkeitsindex am Beispiel der Elektrolytmenge in Anlehnung an LINß 2013, S. 447.

Unter der Annahme eines idealen Benetzungsgrades der Elektrodenmaterialien lässt sich eine Soll-Menge des Elektrolyten errechnen, die, wie in Formel (2.3) beschrieben, den Zielwert  $T$  repräsentiert. Der Qualitätsverlust bei einer Abweichung vom Zielwert lässt sich dabei durch eine parabolische Funktion beschreiben und begründet sich wie folgt: Eine erhöhte Elektrolytmenge trägt nicht weiter zu einer Benetzung der Elektroden bei, führt jedoch zu einer Gewichtszunahme der Zelle und ist daher zu vermeiden. Eine verringerte Elektrolytmenge resultiert wiederum in einem unzureichenden Benetzungsgrad, wodurch die Kapazität der Batteriezelle reduziert wird (KNOCH 2017, S. 72).

Eine wesentliche Limitierung der Qualitätsbewertung durch den kritischen Prozessfähigkeitsindex  $C_{pk}$  und den totalen kritischen Prozessfähigkeitsindex  $C_{pmk}$  stellt allerdings die für eine Berechnung notwendige Mindestanzahl an Stichproben dar. Für eine aussagekräftige Berechnung von Prozessfähigkeitsindizes werden nach BRACKE mindestens 25 Stichproben gefordert (BRACKE 2016, S. 102). Aus diesem Grund lassen sich Prozessfähigkeitsindizes nur eingeschränkt in der frühen Phase eines Produktionsanlaufes anwenden. Eine Qualitätsbeurteilung einzelner Produkte kann alternativ mithilfe einer subjektiven Qualitätsprüfung auf Basis einer reinen expertenbasierten Bewertung der gemessenen Eigenschaften erfolgen.

#### 4.3.2 Selektion von Kennzahlen für die Qualitätsprüfung einer Serienproduktion

Sofern Ursachen-Wirkungszusammenhänge zwischen Prozesskettenelementen vorliegen, sind multivariate Prozessfähigkeitsindizes in Betracht zu ziehen (vgl. Abschnitt 2.2.8). Eine Umsetzung multivariater Prozessfähigkeitsuntersuchungen erfordert eine umfangreiche Datenaufzeichnung von Prozesskettenelementen, um die hierfür notwendigen Korrelationskoeffizienten zu berechnen (LINß 2013, S. 460). Ein solcher Ansatz ist deshalb für einen fortschreitenden Produktionsanlauf bzw. eine Serienfertigung von Batteriezellen geeignet.

Der multivariate Prozessfähigkeitsindex  $MC_{pk}$  repräsentiert eine Kennzahl, welche eine aggregierte Betrachtung mehrerer Eigenschaften ermöglicht. Er berechnet sich auf Basis einer Varianz-Kovarianz-Matrix, welche die Korrelationen zwischen Prozesskettenelementen berücksichtigt. Wie in Abschnitt 2.2.4 erläutert, stellen Korrelationen eine wechselseitige Beziehung zwischen zwei Merkmalsgrößen dar. Diese wechselseitigen Beziehungen werden, wie in Abbildung 32 dargestellt verwendet, um ein Kennzahlensystem aufzubauen. (KORNAS ET AL. 2019B)

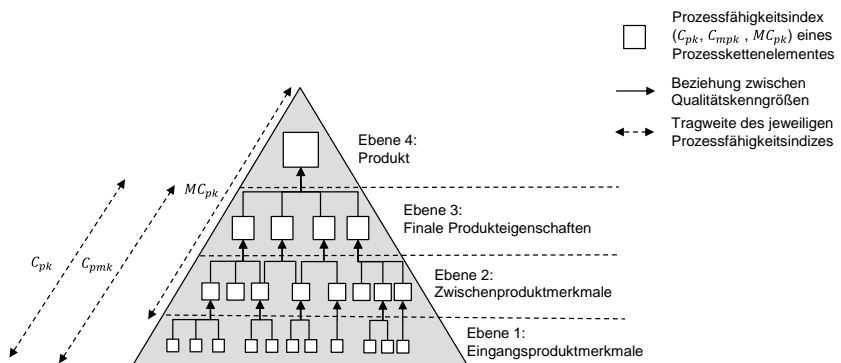


Abbildung 32: Struktur des Kennzahlensystems zur multivariaten Prozessfähigkeitsuntersuchung<sup>11</sup> einer Batteriezellenproduktion nach KORNAS ET AL. 2019B sowie DE-FELIPE & BENEDITO 2017B.

<sup>11</sup> Zur Vereinfachung der Darstellung werden in dem Kennzahlensystem die Eigenschaften von Eingangsproduktmerkmalen und Zwischenproduktmerkmalen sowie finale Produkteigenschaften als Prozesskettenelemente zusammengefasst.

Das Kennzahlensystem zielt darauf ab, eine Vielzahl von Qualitätskenngrößen einer komplexen Prozesskette aggregiert darzustellen. Es spiegelt eine hierarchische Struktur wider, welche nach DE-FELIPE & BENEDITO (2017B) auch als Kaskade bezeichnet werden kann. In dieser Struktur sind insgesamt vier Ebenen erkennbar.

Ebene 1 beinhaltet Eingangsproduktmerkmale wie bspw. Materialeigenschaften oder Prozessparameter. Für jedes hierbei enthaltene Element kann die Qualität mithilfe des kritischen Prozessfähigkeitsindex  $C_{pk}$  oder des totalen kritischen Prozessfähigkeitsindex  $C_{mpk}$  beurteilt werden. Auf welche der beiden Prozessfähigkeitsindizes zurückgegriffen wird, ist von einem Prozessexperten gemäß den zuvor beschriebenen Eigenschaften der jeweiligen Kennzahlen zu bewerten.

Im Falle der Korrelation zweier Eingangsproduktmerkmale aus Ebene 1 können auf Ebene 2 Zwischenproduktmerkmale mithilfe der multivariaten Prozessfähigkeitsindizes  $MC_{pk}$  berechnet werden. So ergibt sich bspw. das Gewicht eines Elektrodenkörpers als  $MC_{pk}$  basierend auf den  $C_{pk}$  der verbauten Anoden- und Kathodenlänge. Sollte das Gewicht des Elektrodenkörpers auf Basis implementierter Sensoren auch physikalisch messbar sein, lässt sich für dieses Merkmal ebenfalls ein  $C_{pk}$  bzw.  $C_{mpk}$  berechnen. Da all die Prozessfähigkeitsindizes eine einheitliche Ordinate besitzen ist eine Vergleichbarkeit der Werte gegeben. Unterschiedliche Werte in den Kennzahlen deuten auf fehlerhafte Korrelationen hin, welche durch Anpassung der Varianz-Kovarianz-Matrix korrigiert werden können. Auf diese Weise kann die Gültigkeit des Kennzahlensystems sichergestellt werden. (KORNAS ET AL. 2019A)

Eine Aggregation von Kennzahlen kann im Weiteren auf Ebene 3 durchgeführt werden, auf welcher die finalen Produkteigenschaften einer Batteriezelle widergespiegelt werden. Durch die Korrelation von Zwischenproduktmerkmalen, wie bspw. dem Gewicht des Zellkörpers und der verwendeten Elektrolytmenge, lässt sich ein  $MC_{pk}$  Wert für das Gesamtgewicht der Batteriezelle berechnen. Eine Aggregation von Informationen kann bis zu Ebene 4 durchgeführt werden, auf welcher das finale Produkt mithilfe einer Kennzahl beschrieben ist. (KORNAS ET AL. 2019A)

Abbildung 32 verdeutlicht die charakteristischen Kaskadeneigenschaften des Kennzahlensystems. Die Pfeile zeigen dabei eine Beziehung zwischen den einzelnen Qualitätselementen auf. Hierdurch wird eine aggregierte Darstellung komplexer Prozessketten ermöglicht. Mithilfe dieser sachlogischen Übersicht kann, ähnlich eines Drilldown Ansatzes, der Detailgrad eines Fehlers erweitert werden (VMDA 66412-1). Dies soll mithilfe von Abbildung 33 verdeutlicht werden, in welcher auf die Nichtkonformität einer Batteriezelle durch eine fehlerhafte Anodenlänge geschlossen werden kann.

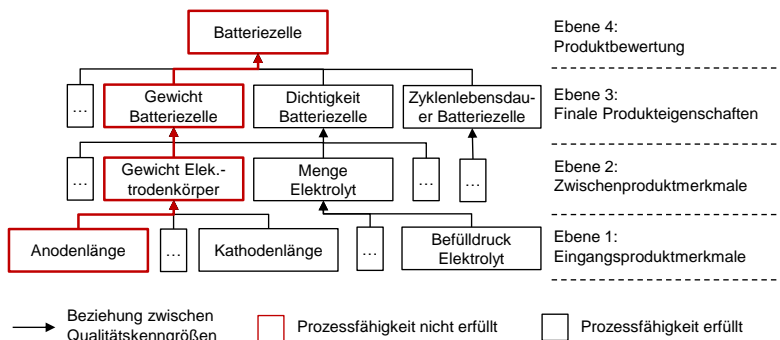


Abbildung 33: Beispiel eines Kennzahlensystems zur multivariaten Prozessfähigkeitsuntersuchung in der Batteriezellenproduktion.

Nach LIU & CHEN (2006) stellen multivariate Kennzahlensysteme häufig ein ergebniskritisches Defizit dar, da eine Auslegung oftmals für normalverteilte Prozessdaten erfolgt (LIU & CHEN 2006, S. 975). Um auch nicht-normalverteilte Daten in ein solches Kennzahlensystem zu integrieren, können Box-Cox (BOX & COX 1982) und Wurzel-Transformation (NIAKI & AB-BASI 2007) eine zweckmäßige Lösung darstellen (vgl. KORNAS ET AL. 2019B, S. 79 und LINß 2013, S. 452).

Eine grundlegende Voraussetzung der bisher diskutierten univariaten und multivariaten Prozessfähigkeitsindizes stellt die Toleranzbestimmung dar. Um eine Auslegung von Toleranzen zu unterstützen, können, wie in Abbildung 34 dargestellt, Histogramme hinzugezogen werden (LINß 2013, 170, 255).




Abbildung 34: Beispiel eines multivariaten Histogramms zur Unterstützung der Toleranzbestimmung.

Die Daten für eine Darstellung von Histogrammen können aus einer Absicherungskampagne resultieren, welche einen Referenzprozess oder ein Referenzprodukt abbildet. Für eine aussagekräftige Bestimmung von Toleranzen sollte eine Absicherungskampagne erfolgen, nachdem die Maschinenfähigkeit verifiziert und die vollständige Prozesskette eingefahren wurde. Um Toleranzen iterativ zu verbessern, können Absicherungskampagnen im Laufe des Produktionsanlaufes wiederholt werden.

Für die multivariaten Prozessfähigkeitsindizes müssen neben den Toleranzen auch Korrelationskoeffizienten identifiziert werden (vgl. Abschnitt 2.2.8). Multivariate Prozessfähigkeitsindizes eignen sich deshalb ausschließlich für einen fortgeschrittenen Produktionsanlauf einer Batteriezellenfertigung, in welcher eine hohe Datenqualität vorliegt, die eine Korrelationsanalyse ermöglicht. Wie in Abschnitt 2.2.4 beschrieben, ist bei einer Korrelationsanalyse auch zwangsläufig eine Kausalitätsprüfung durchzuführen. Kausalitätsprüfungen können nach LINß durch eine Darstellung von Scatterplots unterstützt werden (LINß 2013, S. 179). Dabei lassen sich insbesondere auch multivariate Visualisierungen nutzen, um einer im Anlauf geforderten generischen Betrachtung unterschiedlicher Produkte und Prozesse gerecht zu werden (vgl. Abbildung 35) (KEPSKI & KWOLEK 2013, S. 463).




Abbildung 35: Beispiel einer Korrelationserscheinung unterschiedlicher Produkt- oder Prozesstypen.

#### 4.3.3 Verknüpfung der Kennzahlen zu einem KPI-System

Wie den Anforderungen aus Unterkapitel 4.1 zu entnehmen ist, sind die vorgestellten Prozessfähigkeitsuntersuchungen in ein einheitliches KPI-System zu integrieren, damit eine durchgängige Anwendbarkeit während eines vollständigen Produktionsanlaufes erzielt werden kann.

Ein hierfür geeignetes Werkzeug stellen Qualitätsregelkarten da, welche eine Überwachung und Regelung von Prozessketten unterstützen (vgl. LINß 2013, S. 307). Wie in Abbildung 36 dargestellt, lassen sich die diskutierten Ansätze der Prozessfähigkeitsuntersuchungen aufgrund einheitlicher Ordinate uneingeschränkt in eine Qualitätsregelkarte zusammenführen.

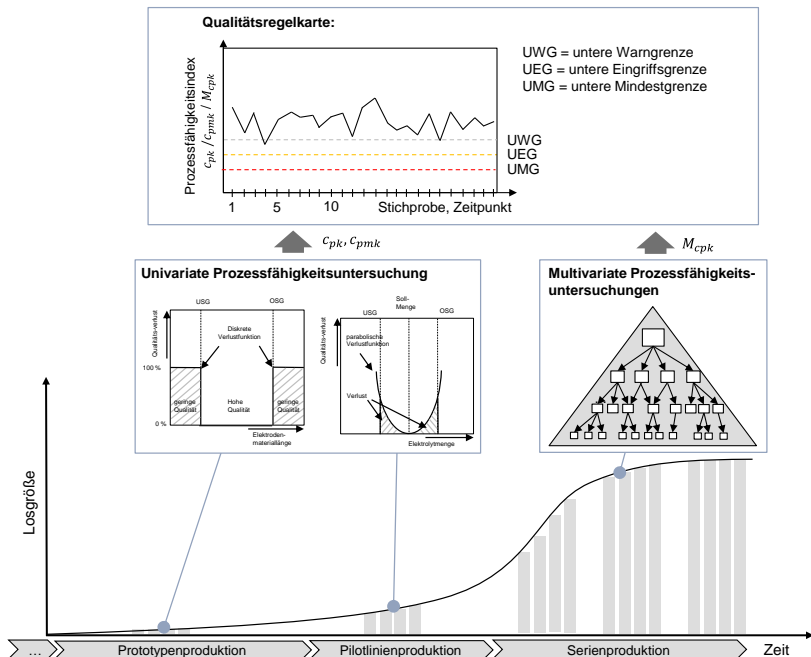


Abbildung 36 Gesamtansatz eines KPI-Systems für den Anlauf und Serienbetrieb einer Batteriezellenproduktion.

Sofern eine statistisch signifikante Anzahl von mindestens 25 Stichproben vorliegt, stellen kritische Prozessfähigkeitsindizes  $C_{pk}$  bzw. totale kritische Prozessfähigkeitsindizes  $C_{mpk}$  eine geeignete Methode zur Qualitätsbewertung dar. Sie lassen sich für die Bewertung einer Prototypenproduktion oder Pilotlinie anwenden. Das multivariate Kennzahlensystem unterstützt durch seine aggregierte Darstellungsweise insbesondere die Bewertung komplexer Prozessketten. Die Methode setzt allerdings die Kenntnis der Korrelationen zwischen Prozesskettenelementen voraus und eignet sich deshalb ausschließlich für einen fortgeschrittenen Produktionsanlauf einer Batteriezellenfertigung, in welcher eine hohe Datenqualität vorliegt.



Zuletzt sei hervorzuheben, dass die Messbarkeit aller qualitätsrelevanten Prozesskettenelemente selten realisiert werden kann. Deshalb wird insbesondere in der Prototypenproduktion, aber auch im weiteren Verlauf des Produktionsanlaufes empfohlen, zusätzlich auf subjektive Prüfmethoden zurückzugreifen.

#### *4.3.4 Zusammenfassung und kritische Gegenüberstellung der Anforderungen*

Die Identifizierung von Fehlern und Produktionsausschüssen stellt die Voraussetzung einer Prozessführung mithilfe eines Qualitätsregelkreises dar und soll mithilfe des diskutierten KPI-Systems realisiert werden. Zur Umsetzung eines Qualitätsmanagementkonzepts in der Batteriezellenproduktion wurden in Unterkapitel 4.1 Einzelziele (Z) und Anforderungen (A) abgeleitet. Der nachfolgende Abschnitt dient einer kritischen Gegenüberstellung der spezifizierten Anforderungen und fasst die wesentlichen Elemente des KPI-Systems zusammen.

Die *Fehleridentifizierung für unterschiedliche Losgrößen (A<sub>23</sub>)* resultiert aus den Eigenschaften eines Produktionsanlaufes und wird mithilfe der verschiedenen Prozessfähigkeitsindizes realisiert. Das Zusammenführen der unterschiedlichen Indizes in ein einheitliches KPI-System auf Basis einer Qualitätsregelkarte stellt dabei ein Hauptmerkmal der vorgestellten Methode dar.

Die *Identifizierung komplexer Fehlerbilder (A<sub>21</sub>)* leitet sich aus den Charakteristiken der Batteriezellenproduktion ab, welche als komplexe Prozesskette zu betrachten ist. Um isolierte Fehler an einzelnen Prozesskettenelementen oder ein Zusammenwirken von mehreren Einflussfaktoren zu berücksichtigen, kann auf univariate oder multivariate Methoden zurückgegriffen werden. Eine Voraussetzung dafür stellt allerdings eine Identifizierung von Toleranzen dar. Toleranzen sind in einem iterativen Prozess zu spezifizieren, wobei zur Unterstützung auf ausgewählte Methoden der Visualisierungen zurückgegriffen werden kann. Diese fördern darüber hinaus eine *produkt- und prozessgenerische Anwendung (A<sub>22</sub>)* des KPI-Systems.

## **4.4 FMEA-basiertes Bayessches Netzwerk**

Wie in Abbildung 37 verdeutlicht, zielt das FMEA-basierte Bayessche Netzwerk darauf ab, ausgehend von den Fehlerbildern des KPI-Systems die Wahrscheinlichkeiten für mögliche Fehlerursachen zu berechnen. Es bildet somit einen integralen Teil der Entscheidungsunterstützung, mithilfe dessen zielorientierte Qualitätsmaßnahmen selektiert werden können. Die Grundlage einer Fehler-Ursachen-Analyse bilden Ursachen-Wirkzusammenhänge. Diese werden in einer FMEA durch Experten dokumentiert. Das Bayessche Netzwerk spiegelt somit einen expertenbasierten Ansatz wider.

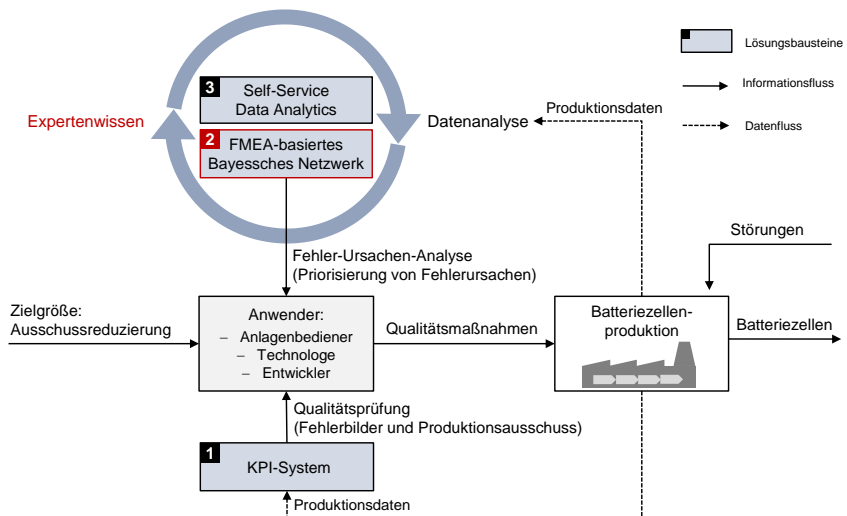


Abbildung 37: Qualitätsmanagementsystems einer Batteriezellenproduktion mit Hervorhebung des FMEA-basierten Bayesschen Netzwerkes.

Entsprechend der Definition aus Abschnitt 2.2.10 stellen Bayessche Netzwerke gerichtete Graphen dar, deren Knoten in der vorliegenden Arbeit durch Fehlerbilder und deren Kanten und Verbindungen durch Ursachen-Wirkzusammenhänge repräsentiert werden. Abbildung 38 soll die Anwendung von Bayesschen Netzwerken an einem Beispiel in der Batteriezellenproduktion verdeutlichen. Zu erkennen ist ein aus der FMEA abgeleitetes initiales Bayessches Netzwerk. In diesem werden unterschiedliche Fehlerbilder dargestellt, die einen Einfluss auf das Gewicht einer Batteriezeile nehmen. Ausgehend von dem initialen Bayesschen Netzwerk können in einem weiteren Schritt Evidenzen berücksichtigt werden, welche Zustände von Fehlern darstellen. Auf Basis von Evidenzen ist in einem Bayesschen Netzwerk das quantitative Schließen auf Ursachen möglich, was als Inferenz bezeichnet wird (BEIERLE & KERN-ISBERNER 2008, S. 401-402). Inferenzen repräsentieren eine wesentliche Operation von Bayesschen Netzwerken und befähigen dazu, Fehlerursachen für unterschiedliche Fälle von Evidenzen zu priorisieren. An dem Beispiel aus Abbildung 38 wird deutlich, dass allein mithilfe einer FMEA und ohne die Verwendung geeigneter statistischer Methoden eine Priorisierung von Fehlerursachen aufgrund der hohen Anzahl an prozessübergreifenden Ursachen-Wirkzusammenhängen nur bedingt möglich ist.

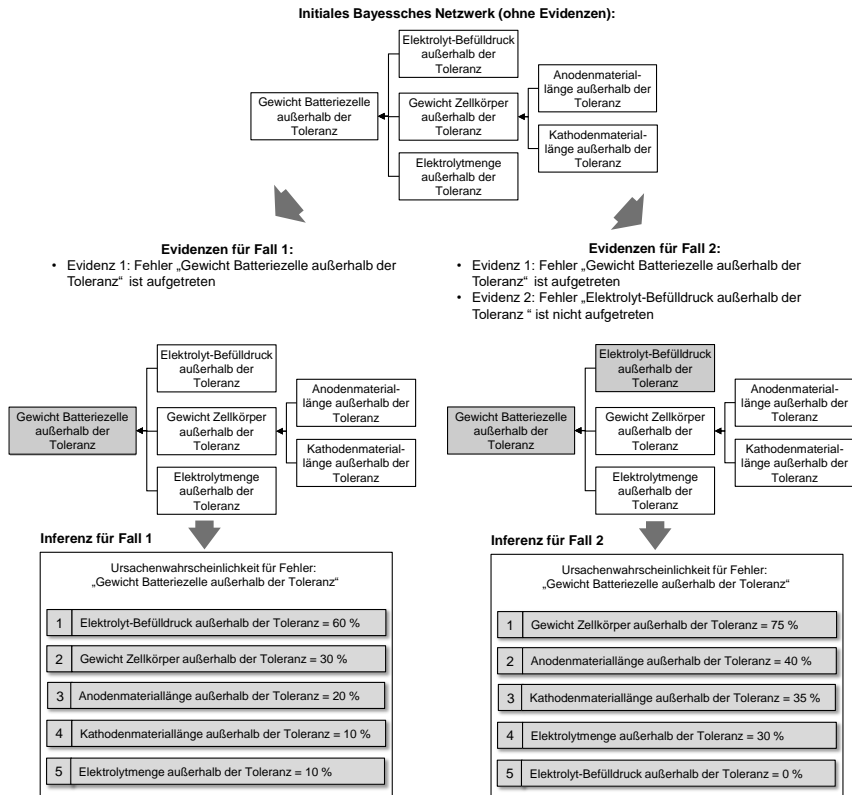


Abbildung 38: Beispiel einer Anwendung von Bayesschen Netzwerken zur Fehler-Ursachen-Analyse in der Batteriezellenproduktion.

Wie in Kapitel 3 beschrieben, werden Bayessche Netzwerke bereits im Sinne einer Fehler-Ursachen-Analyse in fertigungstechnischen Prozessketten verwendet. Eine Übertragbarkeit auf eine Batteriezellenproduktion ist aufgrund identifizierter Defizite allerdings nur bedingt möglich (vgl. Abschnitt 3.2.3). Um den Anforderungen in der komplexen Prozesskette einer Batteriezellenproduktion gerecht zu werden, sind Bayessche Netzwerke um folgende Eigenschaften methodisch weiterzuentwickeln:

- methodische Vorgehensweise zum **Aufbau Bayesscher Netzwerke** (Abschnitt 4.1)
- **Simplifizierung in der Expertenbefragung**, um den Aufwand in der Wissensakquisition zu verringern (Abschnitt 4.4.2)

- **Reduzierung der Berechnungszeit** von Bayesschen Netzwerken, um eine anwendergerechte Nutzung sicherzustellen (Abschnitt 4.4.4)
- Entscheidungsunterstützung zur **Identifikation und Anpassung von Inkonsistenzen**, die während der Wissensakquisition entstehen können (Abschnitt 4.4.5)
- **Quantifizierung unbekannter Ursachen**, um Fehlernetzwerke vollständig beschreiben zu können (Abschnitt 4.4.6)

#### 4.4.1 Aufbau Bayesscher Netzwerke

Entscheidend für den Aufbau eines Bayesschen Netzwerkes ist die Wissensakquisition über Fehlermöglichkeiten und die dazugehörigen bedingten Wahrscheinlichkeiten (vgl. Abschnitt 2.2.10). Aufgrund der in einer Batteriezellenproduktion vorhandenen, hohen Anzahl von Prozesskettenelementen ist der Prozess der Wissensakquisition methodisch zu unterstützen. Die Prozess-FMEA (nachfolgend als FMEA bezeichnet) spiegelt eine etablierte Methodik zum Wissensaufbau über Fehlernetze wider (vgl. Unterkapitel 3.2). Sie ist als Forderung in den Managementsystemen der Automobilindustrie verankert (VDA Band 4, S. 14). Allerdings eignet sich die FMEA nur bedingt für eine Fehler-Ursachen-Analyse. Dies lässt sich damit begründen, dass prozessübergreifende Verkettungen von Fehlern unzureichend betrachtet werden (vgl. GABRIEL ET AL. 2012, S. 4; TENG & HO 1996, S. 12; KORNAS ET AL. 2019B, S. 77). Auch Evidenzen, welche einen Einfluss auf das Fehlernetzwerk nehmen, werden nicht mitberücksichtigt (LINß 2013, S. 581). Wie Tabelle 4-2 zu entnehmen ist, können trotz allem die in einer FMEA akquirierten Bewertungselemente unmittelbar zum Aufbau eines Bayesschen Netzwerkes verwendet werden. Die Beschreibung der einzelnen Elemente aus Tabelle 4-2 und deren Übertragung in ein Bayessches Netzwerk werden nachfolgend im Detail thematisiert.

Tabelle 4-2: Übertragung einer FMEA zu einem Bayesschen Netzwerk in Anlehnung an KIRCHHOF ET AL. 2020.

Bewertungselemente der FMEA	Übertragung	Elemente des Bayesschen Netzwerkes
Fehlermöglichkeit	Graphisch	Fehlerknoten/Kinderknoten
Fehlerursache	Graphisch	Elternknoten
Fehlerzusammenhang	Graphisch	Statistische Abhängigkeit (entspricht einem Ursachen-Wirkzusammenhang)
Kennzahl der Auftretenswahrscheinlichkeit $W(f_j)$	Numerisch	A-priori-Wahrscheinlichkeit $P(f_j)$
Fehlerfolgswahrscheinlichkeit $p_{i,j}$ (Erweiterung der FMEA)	Numerisch	Fehlerfolgswahrscheinlichkeit $p_{i,j}$

### **Fehlermöglichkeiten, Fehlerursachen und Fehlerzusammenhänge**

In der FMEA dient die Bewertung von Fehlermöglichkeiten, Fehlerursachen und Fehlerzusammenhängen dem Aufbau eines grafischen Fehlernetzwerkes. Das grafische Fehlernetzwerk bildet somit die Ursachen-Wirkzusammenhänge aller qualitätsrelevanten Prozesskettenelemente ab. Das Fehlernetzwerk lässt sich vollständig in ein Bayessches Netzwerk übertragen, da es per Definition einem gerichteten azyklischen Graphen entspricht (vgl. Abschnitt 2.2.10). (KIRCHHOF ET AL. 2020)

### **Kennzahl der Auftretenswahrscheinlichkeit $W(f_j)$**

Nach Fertigstellung des Fehlernetzwerkes sind die Fehler der einzelnen Prozesskettenelemente zu bewerten. Im Rahmen einer FMEA werden dabei die Auftretenswahrscheinlichkeit eines Fehlers, die Entdeckungswahrscheinlichkeit der direkt verknüpften Fehlerursachen sowie die Bedeutung der direkt verknüpften Fehlerfolge bewertet (vgl. Abschnitt 2.2.5). Relevant zum Aufbau eines Bayesschen Netzwerkes ist lediglich die Kennzahl der Auftretenswahrscheinlichkeit  $W(f_j)$ , da diese sinngemäß der A-priori-Wahrscheinlichkeit  $P(f_i)$  gleichgesetzt werden kann (KIRCHHOF ET AL. 2020). Die Bewertung der Auftretenswahrscheinlichkeit  $W(f_j)$  erfolgt im Rahmen einer Expertenbefragung, in welcher Punkte von 1 bis 10 vergeben werden. Eine 1 stellt dabei eine geringe Auftretenswahrscheinlichkeit dar, eine 10 eine hohe Auftretenswahrscheinlichkeit (vgl. DIN EN 60812 2015-08). Wie Abbildung 79 aus Anhang 8.1 zu entnehmen ist, kann bei der Umrechnung einer Kennzahl der Auftretenswahrscheinlichkeit  $W(f_j)$  zur A-priori-Wahrscheinlichkeit  $P(f_i)$  auf unterschiedliche Übersetzungen zurückgegriffen werden. Die Übersetzung nach KIRCHHOF ET AL. repräsentiert eine in der Industrie bewährte Möglichkeit und wird deshalb in dieser Arbeit für den Aufbau Bayesscher Netzwerke hinzugezogen (KIRCHHOF ET AL. 2020).

Um den Experten der jeweiligen Bereiche eine vergleichbare Bewertungsgrundlage zur Verfügung zu stellen und die Nachvollziehbarkeit zu unterstützen, kann bei der Vergabe von Auftretenswahrscheinlichkeiten auf Tabelle 4-3 zurückgegriffen werden. Neben einer Beschreibung der einzelnen Bewertungskennzahlen erfolgt hierbei ebenfalls eine Zuordnung zu der Ausschussrate und dem Prozessfähigkeitsindex  $c_{pk}$  (vgl. LINß 2013, S. 624-626). Dies ermöglicht eine methodische Verknüpfung des Bayesschen Netzwerkes mit dem in Abschnitt 4.3 vorgestellten KPI-System. So lässt sich auf Basis der errechneten Prozessfähigkeitsindizes die A-priori-Wahrscheinlichkeit  $P(f_j)$  automatisiert bestimmen. Tabelle 4-3 deckt somit die Anforderungen an einen Produktionsanlauf ab, da sie experten- und datenbasierte Bewertungsmethoden unterstützt.

Tabelle 4-3: Übersetzungstabelle zu Bestimmung der A-priori-Wahrscheinlichkeit.

Kennzahl der Auftretenswahrscheinlichkeit $W(f_j)$	Beschreibung nach LINß 2013, S. 589	Ausschussrate DPMO nach VDA Band 4	Errechneter Prozessfähig- keitsindex $C_{pk}$ (vgl. COSKUN ET AL. 2019)	A-priori-Wahrscheinlichkeit $P(f_j)$ nach KIRCHHOF ET AL. 2020
Experten- basiert		Datenbasiert		
10	Hohe Wahrscheinlichkeit, dass ein Fehler auftritt	500.000	0,225	$50 \cdot 10^{-3}$
9		100.00	0,548	$20 \cdot 10^{-3}$
8	Mäßige Wahrscheinlichkeit, dass ein Fehler auftritt	30.000	0,723	$10 \cdot 10^{-3}$
7		10.000	0,858	$5 \cdot 10^{-3}$
6	Geringe Wahrscheinlichkeit, dass ein Fehler auftritt	5.000	0,935	$2 \cdot 10^{-3}$
5		2.000	1,03	$1 \cdot 10^{-3}$
4		500	1,16	$100 \cdot 10^{-6}$
3	Sehr geringe Wahrscheinlichkeit, dass ein Fehler auftritt	100	1,296	$50 \cdot 10^{-6}$
2		10	1,472	$1 \cdot 10^{-6}$
1	Unwahrscheinlich, dass ein Fehler auftritt	1	1,63	0

Fehlerfolgswahrscheinlichkeit  $p_{i,j}$

Um eine vollständige Beschreibung des Bayesschen Netzwerkes zu erzielen, ist die FMEA um ein zusätzliches Bewertungselement, die sogenannte Fehlerfolgswahrscheinlichkeit (vgl. Tabelle 4-2), zu erweitern. Stellt gemäß Abbildung 39 der Fehler  $F_2$  mit seiner A-priori-Wahrscheinlichkeit  $P(f_2)$  die Ursache des Fehlers  $F_1$  mit seiner A-priori-Wahrscheinlichkeit  $P(f_1)$  dar, so repräsentiert die Fehlerfolgswahrscheinlichkeit  $p_{1,2}$  diejenige Wahrscheinlichkeit, welche zum Auslösen des Fehlers  $F_1$  durch Fehler  $F_2$  führt. (KIRCHHOF ET AL. 2020)




Abbildung 39: Beispiel zur Beschreibung der Fehlerfolgswahrscheinlichkeit.

Die Fehlerfolgswahrscheinlichkeit ist mithilfe einer Prozentzahl im Bereich 0% ( $p = 0$ ) bis 100% ( $p = 1$ ) zu bewerten. Mit  $p = 0$  findet in 0% der Fälle ein Auslösen der Fehlerfolge statt,

mit  $p = 1$  wird ausnahmslos ein Auslösen der Fehlerfolge bewirkt. Es sei allerdings hervorzuheben, dass eine Fehlerfolgewahrscheinlichkeit von 0% ( $p = 0$ ) vorbehaltlich einzusetzen ist, da in diesem Fall eine Verknüpfung von Fehler und Fehlerfolge im Fehlernetzwerk kritisch zu hinterfragen wäre. (KIRCHHOF ET AL. 2020)


Mit dem folgenden Beispiel soll die Fehlerfolgewahrscheinlichkeit im Kontext der Batteriezellenproduktion verdeutlicht werden: In Anlehnung an Abbildung 39 kann Fehler  $F_2$  exemplarisch die Dichtigkeit eines Gehäusedeckels als Teilkomponente einer Batteriezelle repräsentieren. Fehler  $F_1$  zeigt als eine mögliche Fehlerfolge die Dichtigkeit der gefertigten Batteriezelle. Da ein undichter Gehäusedeckel zwangsläufig zu einer undichten Batteriezelle führt, ist in dem beschriebenen Beispiel die Fehlerfolgewahrscheinlichkeit mit  $p = 1$  zu bewerten.

#### 4.4.2 *Simplifizierung der Expertenbefragung*

Die Wissensakquisition ist eine entscheidende Komponente in der Erstellung eines Bayesschen Netzwerkes. Mithilfe der diskutierten Erweiterung einer FMEA (Abschnitt 4.4.1) lasse sich kleine Bayessche Netzwerke, wie bspw. in Abbildung 39 dargestellt, vollständig beschreiben. Im Falle eines komplexen Fehlernetzwerkes, in welchem ein Fehlerknoten mehrere Elternknoten aufweist, müssen für eine vollständige Beschreibung bedingte Wahrscheinlichkeitstabellen aufgestellt werden. Wie in Abschnitt 2.2.10 beschrieben, beinhalten diese die bedingten Wahrscheinlichkeiten aller Auftretenskombinationen von Zuständen der jeweiligen Elternknoten. Aufgrund dessen steigen die Einträge in bedingten Wahrscheinlichkeitstabellen mit der Anzahl der Elternknoten exponentiell an (RUSSELL ET AL. 2016, S. 515). Um den Bewertungsaufwand in der Aufstellung von bedingten Wahrscheinlichkeitstabellen für Experten zu reduzieren, bedarf es somit einer methodischen Unterstützung.

Die Komplexität in der Aufstellung von bedingten Wahrscheinlichkeitstabellen soll mithilfe Abbildung 40 verdeutlicht werden. In dem dargestellten Fehlerknoten mit insgesamt 10 Elternknoten ergeben sich  $2^{10} = 1024$  Auftretenskombinationen von Zuständen. Jeder Kombination ist im Rahmen einer Expertenbewertung eine bedingte Wahrscheinlichkeit zuzuordnen. Eine manuelle Form der Wissensakquisition ist aufgrund des damit einhergehenden hohen Aufwandes nur bedingt möglich. Darüber hinaus würde die hohe Anzahl von Bewertungen die Qualität der Ergebnisse beeinflussen (SRINIVAS 1993).

Bayessches Netzwerk:



Bedingte Wahrscheinlichkeitstabelle des Fehlers  $F_{11}$ :

Auftrittskombinationen der Zustände											Wahrscheinlichkeiten für die jeweiligen Zustände	
$F_{10}$	$F_9$	$F_8$	$F_7$	$F_6$	$F_5$	$F_4$	$F_3$	$F_2$	$F_1$		Fehler eingetreten: $F_{11} = f_{11}$	Fehler nicht eingetreten: $F_{11} = \neg f_{11}$
0	0	0	0	0	0	0	0	0	1		$P(f_{11} f_1, \neg f_2, \neg f_3, \dots, \neg f_{10})$	$P(\neg f_{11} f_1, \neg f_2, \neg f_3, \dots, \neg f_{10})$
0	0	0	0	0	0	0	0	1	0		$P(f_{11} \neg f_1, f_2, \neg f_3, \dots, \neg f_{10})$	$P(\neg f_{11} \neg f_1, f_2, \neg f_3, \dots, \neg f_{10})$
0	0	0	0	0	0	0	1	1			$P(f_{11} f_1, f_2, \neg f_3, \dots, \neg f_{10})$	$P(\neg f_{11} f_1, f_2, \neg f_3, \dots, \neg f_{10})$
⋮												
1	1	1	1	1	1	1	1	1	1		$P(f_{11} f_1, f_2, f_3, \dots, f_{10})$	$P(\neg f_{11} f_1, f_2, f_3, \dots, f_{10})$

Abbildung 40: Beispielhaftes Bayessches Netzwerk inkl. bedingter Wahrscheinlichkeitstabelle.

Einen potenziellen Ansatz zur Komplexitätsreduzierung stellen die in Kapitel 3 beschriebenen Noisy-OR Gates dar. Noisy-OR Gates ermöglichen die Berechnung bedingter Wahrscheinlichkeitstabellen auf Basis der Fehlerfolgswahrscheinlichkeit. Bezogen auf den in Abbildung 40 dargestellten Fall kann dann mithilfe der 10 Fehlerfolgswahrscheinlichkeiten  $p_{11,1} \dots p_{11,10}$  eine automatisierte Bewertung der insgesamt 1024 Auftretenskombinationen erzielt werden. Dies reduziert den Umfang der Bewertung von komplexen Fehlerknoten erheblich. Noisy-OR Gates können allerdings nur unter der Annahme verwendet werden, dass sich alle Ursachen für Fehler in den dazugehörigen Elternknoten finden. Diese Annahme scheint jedoch im Konflikt mit der FMEA zu stehen, da insbesondere zu Beginn eines Produktionsanlaufes nicht davon ausgegangen werden kann, dass alle Fehlerursachen identifiziert wurden. Wie in Abschnitt 4.4.6 gezeigt wird, lässt sich dieser Widerspruch durch die Einführung sogenannter Leak-Nodes aufheben. Leak-Nodes repräsentieren eine Möglichkeit, unbekannte Fehlerursachen mathematisch zu quantifizieren, und vervollständigen damit das Fehlernetzwerk. Sie legitimieren dadurch die Anwendung von Noisy-OR Gates zur Aufstellung von bedingten Wahrscheinlichkeitstabellen. (vgl. Díez 1993 und RUSSELL ET AL. 2016, S. 519)



Mit  $Pa(F_i)$  als Menge aller Elternknoten eines Fehlers  $F_i$  kann die bedingte Wahrscheinlichkeitstabelle unter Anwendung von Noisy-OR Gates wie folgt berechnet werden:


$$P(f_i|Pa(F_i)) = 1 - \prod_{j:F_j=F_j} (1 - p_{i,j})$$

(4.1)

Dabei stellt  $p_{i,j}$  die Fehlerfolgswahrscheinlichkeiten des Fehlers  $F_i$  mit seinen Zuständen  $f_i$  (Fehler aufgetreten oder Fehler nicht aufgetreten) dar. Durch den Index  $j: F_j = f_j$  wird sichergestellt, dass nur diejenigen Elternknoten  $Pa(F_i)$  berücksichtigt werden, die sich in der betrachteten Auftretenskombination auf den Fehler  $F_i$  auswirken. Somit spiegelt sich jede Zustandskombination der Elternknoten  $Pa(F_i)$  in dem Produkt wider und entspricht einer Zeile der bedingten Wahrscheinlichkeitstabelle. Für eine detaillierte Erläuterung der Formel sei auf RUSSELL ET AL. 2016, S. 519 ff. verwiesen.

Mithilfe des in Abbildung 41 dargestellten Fehlernetzwerkes soll die Anwendung von Noisy-OR Gates verdeutlicht werden. Dabei wird die bedingte Wahrscheinlichkeitstabelle für den Fehlerknoten  $F_3$  aufgestellt. In der bedingten Wahrscheinlichkeitstabelle finden sich alle Auftretenskombinationen der Fehler  $F_4$ ,  $F_5$  und  $F_6$ . Die Berechnung jeder Auftretenskombination erfolgt mithilfe der Formel (4.1) und ermöglicht eine Reduzierung der Expertenbewertungen von  $2^3 = 8$  auf insgesamt 3 Einträge. Die 3 Einträge entsprechen dabei den Fehlerfolgswahrscheinlichkeiten  $p_{3,4}$ ,  $p_{3,5}$  und  $p_{3,6}$ .

Bayessches Netzwerk:



Bedingte Wahrscheinlichkeitstabelle für den Fehler  $F_3$ :

Auftrittskombinationen der Zustände			$P(f_3  \text{ Fehlerkombination der Ursachen } )$	
$F_4$ $p_{3,4}=0,1$	$F_5$ $p_{3,5}=0,5$	$F_6$ $p_{3,6}=0,3$	Fehler eingetreten $F_3 = f_3$	Fehler nicht eingetreten $F_3 = \neg f_3$
0	0	0	$1 - 1 = 0$	$\dots = 1$
0	0	1	$1 - 0,7 = 0,3$	$\dots = 0,7$
0	1	0	$1 - 0,5 = 0,5$	$\dots = 0,5$
0	1	1	$1 - 0,5 \cdot 0,7 = 0,65$	$\dots = 0,35$
1	0	0	$1 - 0,9 = 0,1$	$\dots = 0,9$
1	0	1	$1 - 0,9 \cdot 0,7 = 0,37$	$\dots = 0,63$
1	1	0	$1 - 0,9 \cdot 0,5 = 0,55$	$\dots = 0,45$
1	1	1	$1 - 0,9 \cdot 0,5 \cdot 0,7 = 0,69$	$\dots = 0,31$

Abbildung 41: Exemplarische Anwendung der Noisy-OR Gates.

Es lässt sich zusammenfassen, dass Noisy-OR Gates für Experten eine wesentliche Unterstützung darstellen, um den Bewertungsaufwand in der Aufstellung von bedingten Wahrscheinlichkeitstabellen zu reduzieren. Der Mehrwert ist insbesondere für komplexe Prozessketten gegeben, in welchen Fehlerknoten mit einer hohen Anzahl von Elternknoten verknüpft sind.

4.4.3 Durchführung von Inferenzen

Ausgehend von der Erweiterung der FMEA und den Noisy-OR Gates ist es möglich, komplexe Bayessche Netzwerke mit vertretbarem Aufwand vollständig zu erstellen. Das in Abbildung 42 dargestellte Beispiel verdeutlicht die Durchführung einer Fehler-Ursachen-Analyse auf Basis Bayesscher Netzwerke.

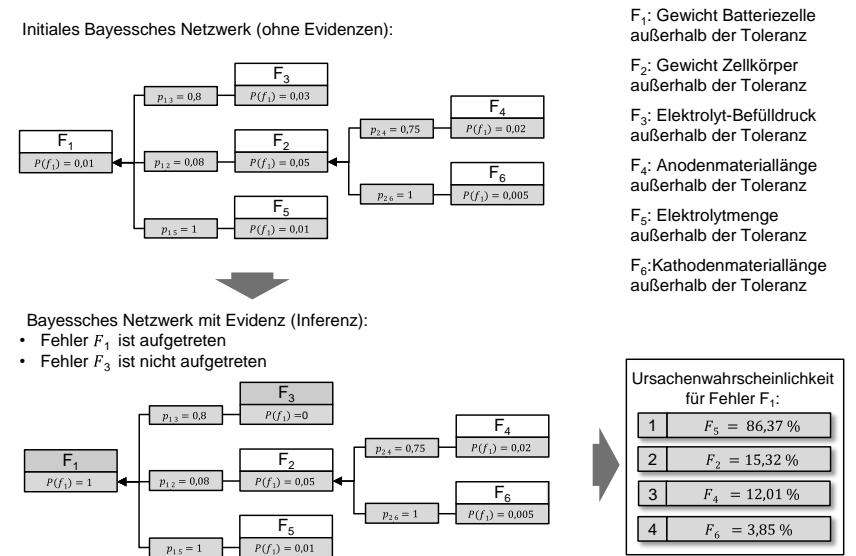


Abbildung 42: Beispiel einer Inferenz zur Fehler-Ursachen-Analyse in Anlehnung an die Berechnung aus Anhang 8.2.

Die Ausgangslage bildet demnach ein mithilfe der FMEA bewertetes Fehlernetzwerk mit den sechs Fehlerknoten  $F_1 \dots F_6$  und dazugehörigen A-priori-Wahrscheinlichkeiten  $P(f_1) \dots P(f_6)$  sowie Fehlerfolgswahrscheinlichkeiten  $p_{i,j}$ . In dem Beispiel liegen darüber hinaus eindeutige

Fehlerzustände vor, welche im Bayesschen Netzwerkes als Evidenz betrachtet werden. Der Zustand des Fehlerknotens  $F_1$  ist demnach als aufgetreten deklariert, wodurch sich seine A-priori-Wahrscheinlichkeit zu  $P(f_1) = 1$  ändert. Gleichzeitig kann ausgeschlossen werden, dass der Fehlerknoten  $F_3$  eine Ursache für den Fehlerknoten  $F_1$  darstellt. Somit ist  $P(f_3) = 0$ . Auf Basis einer Inferenz, welche im Detail Anhang 8.2 entnommen werden kann, lässt sich eine Priorisierung der Ursachenwahrscheinlichkeit für den eingetreten Fehler  $F_1$  berechnen.

Es sei hervorzuheben, dass Bayessche Netzwerke nach KÄPPLER ET AL. (2014, S. 284) zwei Arten von Inferenzen erlauben. Neben dem Schließen von Wirkungen auf Ursachen, welches im Beispiel aus Abbildung 42 verdeutlicht wird, ist umgekehrt auch ein Schließen von Ursachen auf Wirkungen möglich. Basierend auf dem in Anhang 8.2 vorgestellten Rechenansatz lassen sich Bayessche Netzwerke neben einer Fehler-Ursachen-Analyse somit zur Beurteilung von Fehlerauswirkungen verwenden. In Hinblick auf den Qualitätsregelkreises der vorliegenden Forschungsarbeit wird dadurch ein besonderer Mehrwert widerspiegelt, da eine proaktive Prozesskettenführung gestaltet werden kann. Eine Anwendung Bayesscher Netzwerke für eine Fehler-Ursachen-Analyse wird in Abschnitt 4.6.2 sowie Kapitel 5 weiter verdeutlicht.

#### *4.4.4 Reduzierung der Berechnungszeit*

Wie in KIRCHHOF ET AL. gezeigt, weist die Produktion von Batteriezellen ein im Vergleich zum Beispiel aus Abbildung 42 signifikant komplexeres Fehlernetzwerk auf, welches charakterisiert ist durch eine hohe Anzahl an Fehlerknoten und Ursachen-Wirkzusammenhängen (KIRCHHOF ET AL. 2020). Komplexe Fehlernetzwerke können eine kritische Limitierung für die Anwendung Bayesscher Netzwerke darstellen, da sie die Berechnungszeit beeinflussen (KELEMEN ET AL. 2008, S. 215; DEHMER ET AL. 2011, S. 101; POURRET ET AL. 2008, S. 174; DEB ET AL. 2004, S. 886). Um Bayessche Netzwerke in der Produktion von Batteriezellen im Sinne einer dynamischen Fehler-Ursachen-Analyse proaktiv und reaktiv nutzen zu können, ist eine anwendergerechte Berechnungszeit entscheidend und durch geeignete Methoden zu unterstützen.

Der erste methodische Ansatz zielt darauf ab, die Zeit für die Inferenz zu reduzieren. Neben der in Anhang 8.2 aufgezeigten rechnerischen Bestimmung von Fehlerursachenwahrscheinlichkeiten mithilfe der Randverteilungen und des Bayes-Theorems kann alternativ auf Simulationen zurückgegriffen werden (vgl. SHWE & COOPER 1991, S. 453–475). Der Likelihood-Weighting-Algorithmus stellt einen für komplexe Bayessche Netzwerke geeigneten Simulationsansatz zur Verkürzung der Inferenz dar (SCUTARI & DENIS 2015, S. 117). Die Ergebnisse

basieren dabei auf einer Schätzung, welche mithilfe künstlich erzeugter Beobachtungen generiert wird. Die Beobachtungen resultieren aus den bedingten Wahrscheinlichkeitstabellen eines jeweiligen Fehlerknotens und werden in mehreren Simulationsdurchgängen erzeugt. Die Genauigkeit der Ergebnisse sowie die Dauer der Berechnung sind skalierbar und lassen sich über die Anzahl an Simulationsdurchgängen steuern (vgl. RUSSELL ET AL. 2016, S. 532).

Der zweite methodische Ansatz zur Reduzierung von Berechnungszeiten in Bayesschen Netzwerken zielt darauf ab, die Größen der bedingten Wahrscheinlichkeitstabellen zu verringern. Während Noisy-OR Gates lediglich eine Unterstützung in der expertenbasierten Wissensakquisition darstellen, nehmen sie keinen Einfluss auf die Größe der bedingten Wahrscheinlichkeitstabellen. Bedingte Wahrscheinlichkeitstabellen wachsen exponentiell mit der Anzahl von Fehlerknoten und beeinflussen somit direkt die Berechnungs- bzw. Simulationszeit (vgl. Abbildung 40). Eine Reduzierung der Gesamtanzahl von Einträgen in bedingten Wahrscheinlichkeitstabellen kann mithilfe sogenannter Aggregierungsknoten erzielt werden (RUSSELL ET AL. 2016, S. 529-530). Wie Abbildung 43 entnommen werden kann, sind Aggregierungsknoten als Pseudoknoten anzusehen.

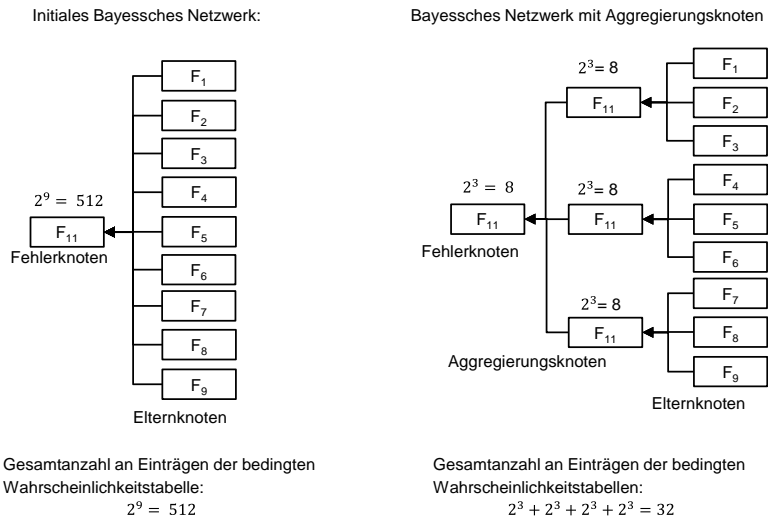


Abbildung 43: Aggregierungsknoten zur Reduzierung bedingter Wahrscheinlichkeitstabellen.

Sie sind vor den Kinderknoten zu implementieren und verfolgen das Ziel, die dazugehörigen Elternknoten zu bündeln. Es sei hervorzuheben, dass Aggregierungsknoten keinen Einfluss

auf die Wahrscheinlichkeitsverteilungen innerhalb eines Netzwerkes haben, da sie auf Basis von Noisy-OR Gates aufgebaut werden und diese der Familie zerlegbarer Wahrscheinlichkeiten zugeordnet werden können (HECKERMAN & BREESE 1996, S. 826-831). Der Einfluss auf die Reduzierung der Einträge von bedingten Wahrscheinlichkeitstabellen mithilfe von Aggregierungsknoten ist exemplarisch in Abbildung 43 beschrieben.

#### 4.4.5 Identifikation und Korrektur von Inkonsistenzen

Neben hohen Berechnungszeiten können auch Inkonsistenzen in den expertenbasierten Bewertungen von Auftretens- und Fehlerfolgswahrscheinlichkeiten eine entscheidende Limitierung in der Anwendung von Bayesschen Netzwerken darstellen. Inkonsistenzen haben einen direkten Einfluss auf die Modellqualität und somit auf die Ergebnisse einer Inferenz (REBAI 2010, S. 55). Sie können insbesondere während der Erstellung einer FMEA entstehen (RENU ET AL. 2016, S. 160). Zur Verdeutlichung von Inkonsistenzen in Bayesschen Netzwerken sei auf Abbildung 44 verwiesen. Demnach besitzt der Fehlerknoten  $F_3$  gemäß der Definition aus Tabelle 4-3 eine geringe Auftretenswahrscheinlichkeit. Diese Bewertung steht im offensichtlichen Widerspruch zu der hohen Auftretenswahrscheinlichkeit sowie Fehlerfolgswahrscheinlichkeit der dazugehörigen Elternknoten. Deren Eigenschaften fördern ein Auslösen des Fehlers  $F_3$ . Ein Hervorrufen des Fehlers  $F_3$  kann darüber hinaus durch die hohe Anzahl an Ursachen, hier also den Elternknoten, bewirkt werden.

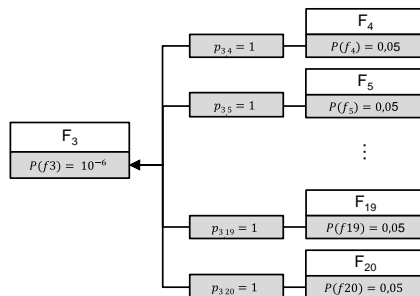


Abbildung 44: Beispiel zur Verdeutlichung von Inkonsistenzen in Bayesschen Netzwerken.

Inkonsistenzen in der Bewertung von Wahrscheinlichkeiten können insbesondere in der Batterieproduktion aufgrund der in Unterkapitel 1.1 beschriebenen Komplexitätsmerkmale

auftreten. Die hohe Anzahl unterschiedlicher Prozessarten führt dazu, dass einzelne Prozessschritte und dazugehörige Produktionsanlagen von speziell designierten Experten betreut werden müssen. Diese sind in der Bewertung von Wahrscheinlichkeiten dadurch limitiert, dass sie lediglich eine bestimmte Anzahl an Variablen gleichzeitig verarbeiten können (HALFORD ET AL. 2005, S. 71). Diese Einschränkung erschwert eine prozessübergreifende Betrachtung der vielen Ursachen-Wirkzusammenhänge und führt potenziell zu inkonsistenten Bewertungen.

Um die Experten in der Bewertung von Auftretenswahrscheinlichkeiten und Fehlerfolgswahrscheinlichkeiten zu unterstützen, sind Inkonsistenzen somit zwingend zu identifizieren. Wie nachfolgend diskutiert, können zudem Algorithmen verwendet werden, um den Experten eine Entscheidungsunterstützung in der Korrektur von Auftretens- und Fehlerfolgswahrscheinlichkeiten zur Verfügung zu stellen, um dadurch Inkonsistenzen aufzuheben.

### Identifikation von Inkonsistenzen

Inkonsistenzen in den expertenbasierten Bewertungen können mithilfe des Satzes der totalen Wahrscheinlichkeit errechnet werden (vgl. Abschnitt 2.2.10, Formel (2.8) sowie TAPPE 2013, S. 26). So lässt sich für einen Fehlerknoten  $F_i$  auf Basis seiner Elternknoten  $Pa(F_i)$  eine Mindest-A-priori-Wahrscheinlichkeit  $P(f_i)_{min}$  ermitteln. Die Mindest-A-priori-Wahrscheinlichkeit  $P(f_i)_{min}$  entspricht einer Auftretenswahrscheinlichkeit, die mindestens vorliegen muss, damit ein Netzwerk konsistent ist. Eine Berechnung der Mindest-A-priori-Wahrscheinlichkeit  $P(f_i)_{min}$  erfolgt durch:

$$P(f_i)_{min} = \sum_{Pa(F_i)} P(f_i|Pa(F_i))P(Pa(F_i)) \quad (4.2)$$

Mithilfe der Summe werden alle möglichen Zustände der Elternknoten  $Pa(F_i)$  abgebildet. Mit  $P(f_i|Pa(F_i))$  werden die Einträge der jeweiligen Zustände aus der bedingten Wahrscheinlichkeitstabelle berücksichtigt.  $P(Pa(F_i))$  stellt die A-priori-Wahrscheinlichkeiten aller Kombinationen der Eltern  $Pa(F_i)$  dar.

Die errechnete Mindest-A-priori-Wahrscheinlichkeit  $P(f_i)_{min}$  eines jeweiligen Fehlerknotens ist in einem nächsten Schritt mit der expertenbasierten A-priori-Wahrscheinlichkeit  $P(f_i)$  zu vergleichen. Gilt für jeden der  $m$  Fehlerknoten im Netzwerk

$$P(f_i) \geq P(f_i)_{min}, \forall i \in \{1, \dots, m\}, \quad (4.3)$$


so wird von einem konsistenten Netzwerk gesprochen. Für

$$P(f_i) < P(f_i)_{\min}, \forall i \in \{1, \dots, m\}, \quad (4.4)$$

weist das Netzwerk eine Inkonsistenz auf. Der Fehlerknoten  $F_i$  wird in diesem Fall durch seine Elternknoten  $Pa(F_i)$  überbestimmt. Um einer Inkonsistenz entgegenzuwirken, sind die Fehlerfolgswahrscheinlichkeiten oder A-priori-Wahrscheinlichkeiten der Elternknoten zu reduzieren oder die A-priori-Wahrscheinlichkeit des betrachteten Fehlerknotens zu erhöhen.

Die Überprüfung von Inkonsistenzen soll anhand des Beispiels in Abbildung 45 a) verdeutlicht werden.

a): Initiales Bayessches Netzwerk:



b): Bayessches Netzwerk mit der Quantifizierung von unbekannten Ursachen:




Abbildung 45: a) Exemplarisches Bayessches Netzwerk zur Berechnung von Inkonsistenzen; b) Darstellung von Leak-Nodes in Bayesschem Netzwerk ausgehend vom Netzwerk aus Abbildung a).

Nach Formel (4.2) lässt sich die Mindest-A-priori-Wahrscheinlichkeit  $P(f_1)_{\min}$  des Fehlerknotens  $F_1$  berechnen als:

$$\begin{aligned} P(f_1)_{\min} &= P(f_1|f_2) \cdot P(f_2) + P(f_1|\neg f_2) \cdot P(\neg f_2), \\ &= 0,75 \cdot 0,2 + 0 \cdot 0,8 = 0,15. \end{aligned} \quad (4.5)$$

Mit  $P(f_1) = 0,2 > P(f_1)_{\min} = 0,15$  kann der Nachweis erbracht werden, dass das Bayessche Netzwerk konsistent ist. Im Falle einer Inkonsistenz ( $P(f_1) < P(f_1)_{\min}$ ) wäre die expertenbasierte Bewertung der A-priori-Wahrscheinlichkeit  $P(f_1)$  zu erhöhen oder die A-priori-Wahrscheinlichkeit  $P(f_2)$  sowie Fehlerfolgswahrscheinlichkeit  $p_{1,2}$  zu verringern.

Um die Konsistenz eines komplexen Bayesschen Netzwerkes mit einer Vielzahl von Ursachen-Wirkzusammenhängen zu überprüfen, ist eine Berechnung von Inkonsistenzen an allen Fehlerknoten durchzuführen, die Elternknoten aufweisen. Wie nachfolgend im Detail erläutert wird, sind Konsistenzprüfungen vorwärtsgerichtet anzuwenden, beginnend vom ersten Elternknoten. Lediglich auf diese Weise kann eine zielorientierte Validierung und Anpassung eines Fehlernetzwerkes sichergestellt werden.

### **Korrektur von Inkonsistenzen**

In simplen Bayesschen Netzwerken, wie bspw. dargestellt in Abbildung 45 a), können Inkonsistenzen von den jeweiligen Experten durch Anpassung der A-priori-Wahrscheinlichkeiten und Fehlerfolgswahrscheinlichkeiten eigenständig korrigiert werden. In komplexen Bayesschen Netzwerken besitzen Anpassungen von Wahrscheinlichkeiten allerdings eine prozessübergreifende Reichweite. Für die Korrektur eines komplexen Bayesschen Netzwerkes liegt somit ein eingeschränkter Lösungsraum mit einer limitierten Anzahl an Freiheitsgraden vor (vgl. SACHS 1972, S. 109). Dieser führt zwangsläufig dazu, dass Anpassungen nicht uneingeschränkt vorgenommen werden können, ohne darauffolgende A-priori-Wahrscheinlichkeiten und Fehlerfolgswahrscheinlichkeiten zu beeinflussen. Aufgrund der Vielzahl an Prozesskettenelementen und prozessübergreifenden Ursachen-Wirkzusammenhängen in der Batteriezellenproduktion, bedarf es somit für Experten einer methodischen Unterstützung zur Korrektur von möglichen Inkonsistenzen.

Den Kern dieser methodischen Unterstützung bildet ein Empfehlungsalgorithmus. Dieser verfolgt das Ziel, den Experten ein korrigiertes Bayessches Netzwerk bereitzustellen, das möglichst deckungsgleich mit dem initialen Netzwerk ist und dabei eine geringe Anzahl an Inkonsistenzen aufweist. Es soll den Experten als Vorlage dienen, die Auftretens- und Fehlerfolgswahrscheinlichkeit der ursprüngliche FMEA zu korrigieren.

Die Suche nach einem konsistenten Netzwerk kann als mathematisches Optimierungsproblem betrachtet werden und wird mithilfe zweier Komponenten gelöst. Die erste Komponente bildet ein evolutionärer Algorithmus, welcher dazu dient, alternative Bayessche Netzwerke (sogenannten Lösungskandidaten) zu generieren. Die zweite Komponente stellt eine Optimierungsfunktion dar, mithilfe deren die alternativen Bayessche Netzwerke bewertet werden. In der Optimierungsfunktion wird einerseits bewertet, inwieweit das alternative Bayessche Netzwerk von dem initialen Netzwerk abweicht. Außerdem wird die absolute Anzahl an Inkonsistenzen gezählt. Es gilt darum, ein alternatives Netzwerk zu identifizieren, in welchem beide Kriterien minimiert werden.



Die Optimierungsfunktion lässt sich wie folgt formulieren:

$$\operatorname{argmin}_p \left\| \frac{c}{\|c\|} \cdot (q(p) - q_e) \right\|^2 + \alpha \cdot \eta \quad (4.6)$$

Dabei repräsentiert  $q(p)$  die Kennzahlen der Auftretenswahrscheinlichkeiten und Fehlerfolgewahrscheinlichkeiten des alternativen Bayesschen Netzwerkes. Durch den Vektor  $q_e$  werden analog die Wahrscheinlichkeiten des initialen, expertenbasierten Bayesschen Netzwerkes repräsentiert. Mithilfe der Funktion  $\operatorname{argmin}_p$  erfolgt eine Minimierung der Optimierungsfunktion. Eine Minimierung kann erzielt werden, indem die Differenz zwischen den expertenbewerteten Wahrscheinlichkeiten  $q_e$  und den Wahrscheinlichkeiten auf Basis des alternativen Bayesschen Netzwerkes  $q(p)$  verringert wird. Im Weiteren kann eine Minimierung durch eine Verringerung der Inkonsistenzen  $\eta$  erfolgen. Eine Steuerung der Optimierungsfunktion und somit eine Anpassung des Lösungsraumes erfolgt über den Hyperparameter  $\alpha$ . Demnach wird durch ein steigendes  $\alpha$  der Fokus auf ein konsistentes Netzwerk gesetzt. Durch ein Verringern von  $\alpha$  wird erreicht, dass das alternative Netzwerk  $q(p)$  möglichst deckungsgleich mit der initialen Expertenbewertung  $q_e$  bleibt. Das Hyperparametertuning repräsentiert demnach einen wichtigen Aspekt bei der Anwendung der Methodik im ingenieurtechnischen Umfeld. Da die Kennzahlen der Auftretenswahrscheinlichkeit im Intervall  $0 - 10$  und die der Fehlerfolgewahrscheinlichkeit im Intervall  $0 - 1$  liegen, wird im Weiteren der Vektor  $c$  eingeführt, welcher einer Normierung der beiden Skalen dient. Es sei hervorzuheben, dass neben einer Normierung hierüber auch eine Selbstbewertung der Sicherheit einer Expertenaussage erfolgen kann. Ist sich bspw. ein Experte über seine Bewertung der Auftretenswahrscheinlichkeit eines Fehlers sicher, so kann der dazugehörige Eintrag im Vektor  $c$  mit einem höheren Faktor versehen werden. Dadurch wird der Bewertungseintrag von der Optimierung weniger beeinflusst. (KIRCHHOF ET AL. 2020)

Alternative Bayessche Netzwerke (Lösungskandidaten) inkl. der dazugehörigen Wahrscheinlichkeiten  $q(p)$  werden mithilfe eines evolutionären Algorithmus ermittelt. Die Funktionsweise eines evolutionären Algorithmus ist Abbildung 46 zu entnehmen. Es sei hervorzuheben, dass die genannte Darstellung lediglich eine Minimalvariante der Methodik abbildet und einer Verdeutlichung dient. Für eine detaillierte Erläuterung zu evolutionären Algorithmen sei auf POHLHEIM (2013) verwiesen. (POHLHEIM 2013, S. 8-10)




Abbildung 46: Grundlegende Struktur eines evolutionären Algorithmus (POHLHEIM 2013, S. 8).

Der Beginn des evolutionären Algorithmus wird durch das Einlesen des initialen, expertenbasierten Bayesschen Netzwerkes  $q_e$  definiert. Hieraus werden zufällige, im Definitionsbereich abgewandelte Formen des initialen Bayesschen Netzwerkes gebildet. Diese werden in einem nächsten Schritt durch eine Zielfunktion bewertet, welche im vorliegenden Anwendungsfall durch die Optimierungsfunktion aus Formel (4.6) repräsentiert wird. Entsprechend dem Ergebnis der Zielfunktion wird jeder abgewandelten Form ein Fitnesswert zugeordnet. Anschließend findet die Überprüfung eines Abbruchkriteriums statt, welches bspw. durch das Erreichen eines Zeitwertes definiert werden kann. Im Falle der Nichterfüllung des Abbruchkriteriums erfolgt die Erstellung einer neuen Population von alternativen Netzwerken. Mithilfe der Anwendung evolutionärer Operatoren (z.B. Rekombination, Mutation) werden dabei Nachkommen gebildet, welche sich aus denjenigen abgewandelten Formen ableiten, die den höchsten Fitnesswert aufweisen. Die beschriebenen Prozessschritte werden bis zum Erreichen des Abbruchkriteriums durchgeführt. Als Ergebnis liegen die Wahrscheinlichkeiten des alternativen Bayesschen Netzwerkes  $q(p)$  vor, auf dessen Basis die initiale FMEA anzupassen ist. (POHLHEIM 2013, S. 8-10)

Es lässt sich zusammenfassen, dass die Korrektur eines inkonsistenten Bayesschen Netzwerkes aufgrund der Vielzahl von Ursachen-Wirkzusammenhängen methodisch unterstützt werden muss. Die Verwendung einer Optimierungsfunktion und eines evolutionären Algorithmus repräsentiert einen geeigneten Ansatz, um den Experten ein möglichst konsistentes Netzwerk bereitzustellen. Zur Verdeutlichung der Funktionsweise dieser beiden Methoden sei auf das Beispiel in Abbildung 47 verwiesen. Das Problem, ein konsistentes Netzwerk zu finden, kann mit der Suche nach der tiefsten Stelle einer Hügellandschaft verglichen werden. Ausgehend von einem Startpunkt (inkonsistentes, expertenbasiertes Bayessches Netzwerk) wird mithilfe des evolutionären Algorithmus der Lösungsraum abgesucht. Jede Lösung entspricht dabei einem Punkt in der Hügellandschaft. Die Höhe eines jeden Punktes lässt sich mithilfe der Optimierungsfunktion bewerten (Formel 4.6). Ein Tiefpunkt repräsentiert dabei ein Netzwerk, welches wenig Inkonsistenzen und eine geringe Abweichung zu der initialen Expertenbewertung

aufweist. In Abbildung 47 wird deutlich, dass die Wahl der Schrittlänge entscheidend ist, um bspw. nicht in einem lokalen Minimum gefangen zu bleiben. Die Schrittlänge lässt sich mithilfe des Hyperparametertunings spezifizieren. (DÖBEL ET AL. 2018, S. 50)




Abbildung 47: Veranschaulichung der Suche nach einem konsistenten Netzwerk (nach DÖBEL ET AL. 2018, S. 50).

Um in verfahrenstechnischen oder fertigungstechnischen Prozessketten eine zielorientierte Optimierung zu bewirken, ist eine vorwärts gerichtete Anwendung des Empfehlungsalgorithmus anzustreben. Wie in Abbildung 48 dargestellt, ist ausgehend von dem ersten Prozessschritt eine chronologische, prozessweise Überprüfung und Anpassung durchzuführen.




Abbildung 48: Vorgehen zur Konsistenzprüfung und Korrektur komplexer Bayesscher Netzwerke.

Diese Vorgehensweise korrespondiert mit der Durchführung der Strukturanalyse einer FMEA (WERDICH 2012, S. 37). Sie unterstützt im Weiteren die FMEA, da auf diese Weise die Experten unmittelbar Rückmeldung erhalten, ob Bewertungskennzahlen sinnvoll vergeben worden sind.

#### 4.4.6 Quantifizierung von unbekannten Fehlerursachen

Insbesondere während eines Produktionsanlaufes, aber auch im Serienbetrieb einer Batteriezellenproduktion ist zu berücksichtigen, dass der expertenbasierte Aufbau eines Fehlernetzwerkes unvollständig sein könnte. So muss die Annahme getroffen werden, dass bei jedem Fehlerknoten noch weitere Fehlerursachen vorliegen könnten, die von den Experten nicht identifiziert wurden. Die Gründe für unvollständige Fehlernetzwerke lassen sich auf die hohe Komplexität in der Batteriezellenproduktion zurückführen (KORNAS ET AL. 2019B, S. 76-78). Unvollständige Fehlernetzwerke stehen grundsätzlich im Widerspruch zu den in Abschnitt 4.4.2 eingeführten Noisy-OR Gates. Die Verwendung von Noisy-OR Gates zur Berechnung von bedingten Wahrscheinlichkeitstabellen fordert demnach, dass sich alle Ursachen in den dazugehörigen Elternknoten finden (RUSSELL ET AL. 2016, S. 519).

Um diesen Widerspruch aufzuheben, werden nachfolgend Leak-Nodes eingeführt, welche eine mathematische Quantifizierung aller unbekannten Fehlerursachen ermöglichen (DÍEZ 1993). Auf diese Weise lässt sich ein Fehlernetzwerk vollständig beschreiben und folglich eine Anwendung von Noisy-OR Gates legitimieren. (KIRCHHOF ET AL. 2020)

Leak-Nodes können als quantifizierte Erkenntnislücke zwischen einem Fehler  $F_i$  und seinen Eltern  $Pa(F_i)$  betrachtet werden (vgl. DÍEZ 1993). Die Voraussetzung zur Berechnung von Leak-Nodes bilden Konsistenzprüfungen (vgl. Formel (4.2)). Demnach sind inkonsistente Netzwerke als überbestimmt zu betrachten. Sie lassen somit keinen Raum zur Quantifizierung einer Erkenntnislücke offen.

Wie auch alle anderen Fehlerknoten eines Bayesschen Netzwerkes, werden Leak-Nodes durch eine Auftretenswahrscheinlichkeit  $P(f_i)$  und Fehlerfolgswahrscheinlichkeit  $p_{i|l}$  charakterisiert. Es wird festgelegt, dass die Fehlerfolgswahrscheinlichkeit einen Wert von  $p_{i|l} = 1$  (100%) besitzt. Die A-priori-Wahrscheinlichkeit  $P(f_i)$  eines Leak-Nodes berechnet sich wie folgt (KIRCHHOF ET AL. 2020):

$$P(f_i) = 1 - \frac{P(\neg f_i)}{\sum_{Pa(F_i)(\prod_{j:F_j=f_j}(1-p_{i|j})) \cdot P(Pa(F_i))} . \quad (4.7)$$

Dabei repräsentiert  $P(\neg f_i)$  die Wahrscheinlichkeit des Nichtauftretens von Fehler  $F_i$ . Durch den Index  $j: F_j = f_j$  wird sichergestellt, dass nur diejenigen Elternknoten  $Pa(F_i)$  berücksichtigt werden, die sich auf den Fehler  $F_i$  auswirken. Mit  $p_{i,j}$  wird die Fehlerfolgswahrscheinlichkeit des Fehlers  $F_i$  mit seinen Zuständen  $f_i$  (Fehler aufgetreten oder Fehler nicht aufgetreten) dargestellt.  $P(Pa(F_i))$  repräsentiert die A-priori-Wahrscheinlichkeiten aller Kombinationen der Eltern  $Pa(F_i)$ . Für eine detaillierte Beschreibung und Herleitung der Formel sei auf KIRCHHOFF ET AL. 2020 verwiesen.

Die Berechnung und Anwendung von Leak-Nodes soll mithilfe des Beispiels aus Abbildung 45 b) verdeutlicht werden. Für das dargestellte Bayessche Netzwerk konnte bereits ein Konsistenznachweis erbracht werden (vgl. Formel (4.5)). Es liegt somit eine Erkenntnislücke vor, welche durch Anwendung der Leak-Nodes quantifiziert werden kann. Mit  $p_{i,j} = 1$  als Fehlerfolgswahrscheinlichkeit und

$$P(f_i) = 1 - \frac{P(\neg f_i)}{\sum_{Pa(F_i)} (\prod_{j: F_j = f_j} (1 - p_{i,j})) \cdot P(Pa(F_i))} = 1 - \frac{0.8}{0.8 + (1 - 0.75) \cdot 0.2} = 0,0588 \quad (4.8)$$

als A-priori-Wahrscheinlichkeit des Leak-Nodes lässt sich die Erkenntnislücke nun vollständig beschreiben. Diese bildet als unbekannte Ursache einen weiteren Elternknoten des vorliegenden Netzwerkes. Es lässt sich zusammenfassen, dass der Fehler  $F_1$  nun mit allen Fehlerursachen verknüpft ist, sodass die Anforderung zur Anwendung der Noisy-OR Gates erfüllt ist.

#### 4.4.7 Zusammenfassung und kritische Gegenüberstellung der Anforderungen

Wie im Konzeptbild der vorliegenden Arbeit verdeutlicht (vgl. Abbildung 27), stellt die Fehler-Ursachen-Analyse, abgeleitet aus den im KPI-System identifizierten Fehlerbildern, den Kernbaustein des Qualitätsregelkreises dar. Aus Kapitel 3.4 lässt sich ableiten, dass das Bayessche Netzwerke eine geeignete Methode der Fehlerursachenanalyse repräsentieren. Dies kann damit begründet werden, dass entgegen traditioneller Methoden, wie bspw. einer FMEA, in Bayesschen Netzwerken ebenfalls die Zustände von Fehlern berücksichtigt werden. Auf diese Weise wird ein quantitatives Schließen auf Ursachen ermöglicht, was als Inferenz bezeichnet wird. Dadurch können Qualitätsmaßnahmen priorisiert werden. Eine Anwendung von Bayesschen Netzwerken in einer Batteriezellenproduktion ist allerdings aufgrund der in Kapitel 3 identifizierten Defizite nur bedingt möglich. Deshalb wurde eine Weiterentwicklung in den folgenden Bereichen gefordert:

- ein methodische Vorgehensweise zum Aufbau Bayesscher Netzwerke (Abschnitt 4.1)

- eine Simplifizierung in der Expertenbefragung, um den Aufwand in der Wissensakquisition zu verringern (Abschnitt 4.4.2)
- eine Reduzierung der Berechnungszeit von Bayesschen Netzwerken, um eine anwendergerechte Nutzung sicherzustellen (Abschnitt 4.4.4)
- eine Entscheidungsunterstützung zur Identifikation und Anpassung von Inkonsistenzen, die während der Wissensakquisition entstehen können (Abschnitt 4.4.5)
- eine Quantifizierung unbekannter Ursachen, um Fehlernetzwerke vollständig beschreiben zu können (Abschnitt 4.4.6)

Der vorliegende Abschnitt dient einer Zusammenfassung und einer kritischen Gegenüberstellung der in Unterkapitel 4.1 spezifizierten Anforderungen.

Die Anforderung an eine *methodische Unterstützung in der expertenbasierten Erfassung von Ursachen-Wirkzusammenhängen* (**A<sub>11</sub>**) ist insbesondere während des Aufbaus von Bayesschen Netzwerken zu berücksichtigen. Wie aufgezeigt wurde, lässt sich die traditionelle FMEA mithilfe geeigneter Erweiterungen in ein Bayessches Netzwerk übersetzen und ist so als Werkzeug zur systematischen Akquirierung von Fehlermöglichkeiten und Wahrscheinlichkeiten anzusehen. Die Methode unterstützt eine Betrachtung *unterschiedlicher Expertenmeinungen* (**A<sub>12</sub>**) und eignet sich insbesondere für *komplexe Prozessketten* (**A<sub>13</sub>**). Kernbausteine bilden dabei die in Tabelle 4-3 definierten Übersetzungsmöglichkeiten zur Bestimmung der A-priori-Wahrscheinlichkeit sowie die Einführung der Fehlerlogwahrscheinlichkeit.

Eine Herausforderung im Aufbau Bayesscher Netzwerke stellen bedingte Wahrscheinlichkeitstabellen dar. Diese beinhalten Wahrscheinlichkeiten für Auftretenskombinationen von Fehlern und wachsen exponentiell mit der Anzahl an Elternknoten. Aufgrund der hohen Anzahl an Prozesskettenelementen in der Batteriezellenproduktion stellt die Simplifizierung in der Expertenbefragung eine wichtige Anforderung dar, um den Aufwand in der Wissensakquisition zu verringern. Es wurde aufgezeigt, dass Noisy-OR Gates eine methodische Unterstützung für Experten darstellen, um den Bewertungsaufwand in der Aufstellung von bedingten Wahrscheinlichkeitstabellen maßgeblich zu reduzieren. Allerdings fordert die Verwendung von Noisy-OR Gates ein vollständig beschriebenes Fehlernetzwerk. Um die Anwendung von Noisy-OR Gates zu legitimieren, wurden Leak-Nodes eingeführt. Diese stellen eine etablierte Methode dar, um ein Bayessches Netzwerk zu vervollständigen (vgl. RUSSELL ET AL. 2016, S. 519). Der in Abschnitt 4.4.6 vorgestellte Ansatz geht allerdings über ein alleiniges Hinzufügen von Leak-Nodes hinaus, da er zudem eine mathematische Quantifizierung von unbekannten Fehlerursachen ermöglicht. Auf diese Weise lassen sich Erkenntnislücken priorisiert aufzeigen.

Zuletzt stellen auch Inkonsistenzen eine Herausforderung im Aufbau komplexer Bayesscher Netzwerke dar. Inkonsistenzen resultieren aus Unsicherheit in der expertenbasierten Akquisition von Wahrscheinlichkeiten und treten aufgrund beschriebener Komplexitätsmerkmale insbesondere in der Batteriezellenproduktion auf. Es wurde eine Möglichkeit zur Identifizierung von Inkonsistenzen aufgezeigt sowie ein Empfehlungsalgorithmus entwickelt, um Bayessche Netzwerke im Anwendungsfall einer Batteriezellenproduktion zu korrigieren.

Die *Praxistauglichkeit* (**A<sub>31</sub>**) bildet eine weitere relevante Anforderung an die Fehler-Ursachen-Analyse. Um Inferenzen dynamisch nutzen zu können und eine Ad-hoc-Fehler-Ursachen-Analyse zu ermöglichen, wird eine zeit- und ressourceneffiziente Berechnung gefordert. Wie aufgezeigt wurde, stellen Simulationsansätze auf Basis des Likelihood-Weighting-Algorithmus als auch Aggregierungsknoten zielführende Methoden dar, um die Berechnungszeit zu verkürzen und eine Praxistauglichkeit in der Batteriezellenproduktion zu fördern.

Die *Nachvollziehbarkeit der Ergebnisse* (**A<sub>33</sub>**), als eine weitere Anforderung an die Fehler-Ursachen-Analyse, wird mithilfe der charakteristischen Eigenschaften Bayesscher Netzwerke erzielt. Demnach repräsentieren Bayessche Netzwerk gerichtete azyklische Graphen, die auch prozessübergreifende Ursachen-Wirkzusammenhänge vollständig abbilden können. Diese unterstützen die Experten bei einer gesamthaften Betrachtung der Produktion.

Traditionelle Qualitätsmanagementansätze basieren meist auf deskriptiven Verfahren. Qualitätsmaßnahmen werden dabei reaktiv durchgeführt. Es sei hervorzuheben, dass mithilfe Bayesscher Netzwerke auch Fehlerauswirkungen berücksichtigt werden können, was einen *proaktiven Ansatz zur Prozesskettenführung* (**A<sub>46</sub>**) widerspiegelt.

## 4.5 Self-Service Data Analytics

Die Identifizierung von Ursachen-Wirkzusammenhängen, als Voraussetzung für eine Fehler-Ursachen-Analyse, wird, wie in Abschnitt 4.1 beschrieben, mithilfe einer erweiterten Form der FMEA erzielt. Ein solcher expertenbasierter Ansatz bildet einen Mehrwert in einer frühen Phase eines Produktionsanlaufes, in welchem keine Produktionsdaten zur Quantifizierung von Zusammenhängen vorliegen. Allerdings ist diese Form der Wissensakquisition mit einer Unsicherheit behaftet (WESTERMEIER 2016, S. 3). Ab Beginn einer Datenaufzeichnung und unter der Prämisse einer hohen Datenqualität lassen sich zur Identifizierung von Ursachen-Wirkzusammenhängen alternativ Methoden der Datenanalyse anwenden (SCHENDERA 2007, S. 6). Allerdings kann die Prämisse einer hohen Datenqualität nicht zwangsläufig eingehalten werden, da sich aus Kostengründen oder Gründen der Zugänglichkeit bzw. Messbarkeit nicht alle qualitätsrelevanten Prozesskettenelemente erfassen lassen. Daher wird für die Identifizierung

von Ursachen-Wirkzusammenhängen ein synergetischer Ansatz verfolgt, in welchem das Potenzial durch die Verknüpfung von experten- und datenbasierten Methoden gehoben werden soll (vgl. Abbildung 49).

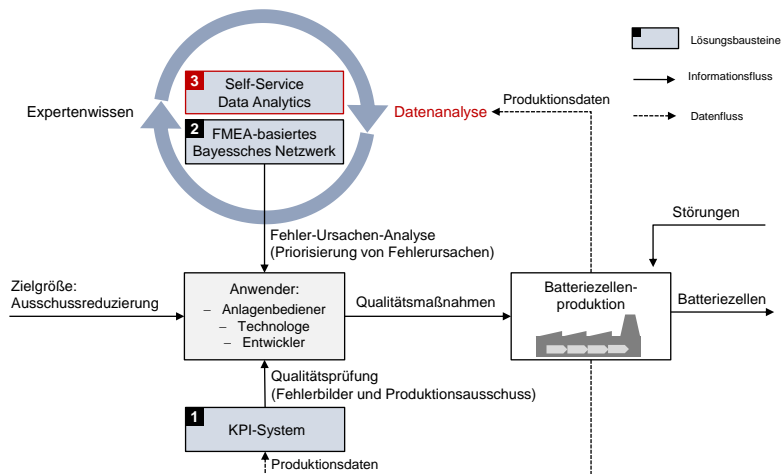


Abbildung 49: Qualitätsmanagementsystem einer Batteriezellenproduktion mit Hervorhebung der Self-Service Data Analytics.

Dabei kann das Expertenwissen genutzt werden, um die Datenanalyse zu unterstützen und umgekehrt verfolgt die Datenanalyse das Ziel, das Expertenwissen zu schärfen. Nach KORNAS ET AL. lässt sich auf diese Weise eine ganzheitliche Analyse von Ursachen-Wirkzusammenhängen erzielen, welche für einen vollständigen Produktionsanlauf einer Batteriezellenfertigung geeignet ist (KORNAS ET AL. 2019A, S. 385).

Aus dem Stand der Forschung (Kapitel 3) lässt sich ableiten, dass datenbasierte Ansätze allerdings noch erhebliche Forschungsdefizite aufweisen. Das lässt sich damit begründen, dass nach CAO & ZHANG die Ergebnisse vieler Data-Mining-Prozesse für Anwender häufig nicht verwertbar sind. Demnach repräsentiert das Data-Mining ohne die Unterstützung von Experten häufig einen rein datengesteuerten Trial-and-Error-Prozess, welcher keinen Mehrwert für reale Anwendungen bietet (CAO & ZHANG 2008, S. 49, CAO 2010). Eine hohe Anwendbarkeit in der Datenanalyse stellt eine Voraussetzung des synergetischen Qualitätsmanagementansatzes.



Es lassen sich somit zwei wesentliche Forschungslücken identifizieren, welche wie folgt zusammengefasst werden können und die Struktur des vorliegenden Unterkapitels bilden:

- die Erarbeitung eines **expertengestützten Konzepts zur Datenanalyse**, welches hier als Self-Service Data Analytics bezeichnet wird und darauf abzielt, Experten in den Prozess der Datenanalyse zu integrieren, um einen zielgerichteten und auf die Industrie übertragbaren Wissensgewinn zu fördern (Abschnitt 4.5.1)
- die synergetische **Verknüpfung von experten- und datenbasierten Methoden**, um eine ganzheitliche Analyse von Ursachen-Wirkzusammenhängen zu erzielen. Dies impliziert eine methodische Verknüpfung des auf der FMEA-basierten Bayesschen Netzwerkes und dem zu erarbeitenden expertengestützten Konzepts zur Datenanalyse (Abschnitt 4.5.2)

Der Schwerpunkt des Unterkapitels liegt insbesondere auf der Auslegung eines Gesamtkonzepts zur Datenanalyse, in welchem die einzelnen Phasen, Interaktionen mit den Experten sowie notwendige Schnittstellen thematisiert werden. Das nachfolgend beschriebene Konzept erhebt keinen Anspruch auf Vollständigkeit bzgl. einer Datensicherungs-, Datenbereitstellungs- oder Datenvorverarbeitungsmethode. Auch Techniken zur Umsetzung von Datenanalysemethoden werden nicht betrachtet.

#### *4.5.1 Expertengestütztes Konzept zur Datenanalyse*

Obwohl gemäß Abschnitt 2.2.9 CRISP-DM einen in der Industrie fest etablierten Prozess zur Datenanalyse darstellt, liegt ein wesentliches Defizit des Ansatzes darin, dass die Rolle des Experten und seine Interaktionen mit der Datenanalyse nicht ausreichend hervorgehoben werden (KORNAS ET AL. 2019A, S. 381). Traditionelle Prozesse der Datenanalyse setzen den Fokus allein auf Daten und Methoden für deren Analyse (CAO 2010, S. 11). Eine solche einseitige Konzeptausrichtung ist aus industrieller Sicht nicht zielführend, da insbesondere zu Beginn eines Produktionsanlaufes Ursachen-Wirkzusammenhänge nicht zwangsläufig auf Basis von Daten quantifiziert werden können. Des Weiteren werden hierbei Einschränkungen vernachlässigt, welche bspw. aus Umweltfaktoren bzw. sozialen oder organisatorische Faktoren resultieren (TANIAR 2008, S. 206). Der Prozess des Wissensgewinns muss deshalb durchgängig von Experten begleitet werden.

Im Weiteren liegt der Fokus vieler Datenanalyseansätze darin, innovative Vorgehensweisen mithilfe neuer Algorithmen zu entwickeln (CAO 2010, S. 5). Für eine industrienähe Anwendung ist allerdings ein problemorientierter Prozess zur Identifikation kausaler Zusammenhänge

von Relevanz. Eine industriennahe Anwendung wird häufig durch Rahmenbedingungen charakterisiert, die bspw. aus internen Arbeitsabläufen oder Datenschutzbestimmungen resultieren (TANIAR 2008, S. 208). Die Integration von Domänenwissen in einem expertengestützten Prozess stellt eine Möglichkeit dar, Rahmenbedingungen zu berücksichtigen (ANAND ET AL. 1995, S. 39). Darüber hinaus kann eine solche Durchführung entscheidende Potenziale heben, um Iterationsschritte zu verkürzen und Agilität zu fördern.

Zuletzt repräsentiert die Evaluierung einen weiteren relevanten Aspekt zur zielführenden Auslegung eines Datenanalyseprozesses. In traditionellen Ansätzen werden die Ergebnisse der Datenanalyse allein auf Basis statistischer Metriken bewertet (CAO 2010, S. 22). So kann bspw. die mittlere quadratische Abweichung als Qualitätskriterium hinzugezogen werden, um die Güte eines verwendeten Modells zu bewerten (PERNER 2007, S. 208). Ein Modell kann als geeignet angesehen werden, wenn sich die Metriken innerhalb eines spezifizierten Bereiches befinden. Um den Nutzen der Datenanalyseergebnisse im industriellen Kontext zu prüfen, bedarf es allerdings darüber hinaus einer Experten zur Dateninterpretation (CAO 2010, S. 17).

Es lässt sich zusammenfassen, dass traditionelle Prozessmodelle der Datenanalyse, wie bspw. CRISP-DM, nicht zielführend für eine industrielle Anwendung sind. Ein Potenzial soll durch die Integration von Experten gehoben werden. Aus den thematisierten Aspekten leitet sich das Konzept einer Self-Service Data Analytics ab, welches in Abbildung 50 dargestellt ist und nachfolgend diskutiert wird.

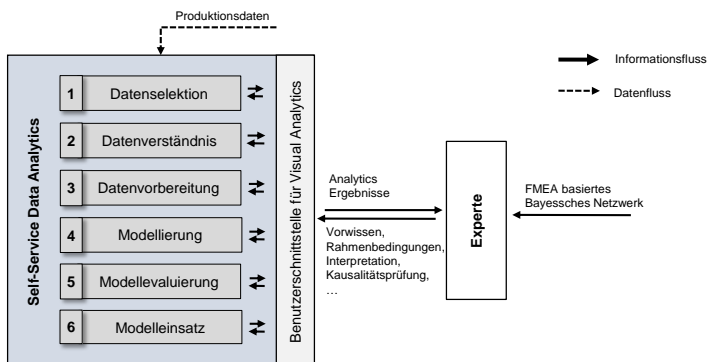


Abbildung 50: Konzeptbild der Self-Service Data Analytics.

Die Self-Service Data Analytics zeichnet sich demnach durch insgesamt sechs Prozessphasen aus, welche teilweise an die Vorgehensweise von CRISP-DM angelehnt sind. Die erste

Phase der Datenanalyse nach CRISP-DM beginnt mit dem Aufgabenverständnis (im Englischen „Business Understanding“) (vgl. SCHACHT & LANQUILLON 2019, S. 113). Im Falle eines von Experten durchgeführten Vorgehens kann dieser Schritt vernachlässigt werden, da der fachliche Kontext und die Ziele bereits vorliegen. Um die Experten zu einer selbständigen Datenanalyse zu befähigen, wird eine Benutzerschnittstelle auf Basis von Visual Analytics bereitgestellt. Visual Analytics ist eine automatisierte und interaktive Analysetechnik, welche nach KALUZA ET AL. die Bereiche Mensch-Computer-Interaktion, Data-Mining und Visualisierung verknüpft. Mithilfe geeigneter Methoden und Werkzeuge lässt sich auf diese Weise eine Interpretierbarkeit der Ergebnisse fördern (KALUZA ET AL. 2018, S. 38; HUTCHISON ET AL. 2010, S. 154-175).

Ein weiteres Alleinstellungsmerkmal des Konzeptbildes stellt das Bayessche Netzwerk dar, auf welches der Experte während der Datenanalyse zugreifen kann. Es repräsentiert gemäß Unterkapitel 4.4 eine Datenbank, in welcher das prozessübergreifende Domänenwissen hinterlegt ist. Es ist somit als methodische Unterstützung zu verstehen, da es eine Betrachtungsweise aus unterschiedlichen Fachbereichen ermöglicht. (KORNAS ET AL. 2019A).

Es kann zusammengefasst werden, dass das in Abbildung 50 dargestellte Prozessmodell die Agilität eines Datenanalyseprojektes potenziell fördert. Dies kann damit begründet werden, dass der Experte in der Lage ist, Anpassungen an jeder Prozessphase eigenständig durchzuführen. Dadurch lassen sich Iterationszeiten verkürzen. Im Folgenden werden die einzelnen Phasen der Self-Service Data Analytics sowie die Interaktion mit dem Bayesschen Netzwerk im Detail diskutiert.

### **Datenselektion**

Die Datenselektion repräsentiert die erste Phase der Self-Service Data Analytics. Wie in Abbildung 51 verdeutlicht, wird dabei das Ziel verfolgt, die für die nachfolgenden Analysenschritte relevanten Daten zu aggregieren und zu reduzieren. Eine frühzeitige Reduktion der Daten ist anzustreben, um die Berechnungszeiten und Ergebnisse zu optimieren, da nach GELLRICH ET AL. und REINARTZ Datenbanken mehr Informationen enthalten können als für eine Analyse notwendig (GELLRICH ET AL. 2019, S. 16; REINARTZ 1999, S. 19). Die Datenquellen innerhalb einer Produktion von Batteriezellen können wie folgt kategorisiert werden:

- **Beginn-of-Line-Daten** fassen alle Eigenschaften von Eingangsprodukten zusammen und können auch als Eingangsproduktmerkmale bezeichnet werden. Hierzu lassen sich bspw. Eigenschaften von verwendeten Elektrolyten oder Aktivmaterialien zuordnen.

- **Produktionsdaten** beschreiben Eigenschaften von Prozesskettenelementen bzw. Zwischenproduktmerkmale sowie Informationen der technischen Gebäudeausrüstung. Diese können Soll- oder Ist-Werte von Maschinenparametern oder Eigenschaften von Zwischenprodukten beinhalten.
- **End-of-Line-Daten** resultieren aus der Überprüfung der Funktionalität des fertigen Produktes und werden bspw. durch geometrische oder chemische Eigenschaften der Batteriezelle definiert. Die Kapazität oder Spannung stellt mögliche End-of-Line-Daten dar. (KAMPKER ET AL. 2013, S. 245)

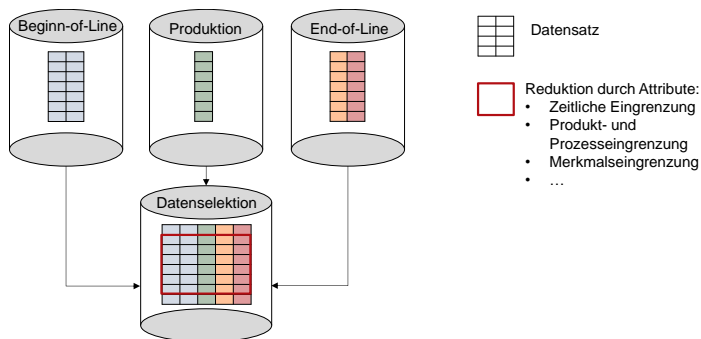


Abbildung 51: Prozessphase zur Datenselektion.

Die Interpretation von Metadaten und die Eingrenzung eines Datensatzes basieren häufig auf den Vorkenntnissen der Experten. Damit die Experten einen ganzheitlichen Blick auf die komplexe Prozesskette einer Batteriezellenproduktion erhalten, können sie methodisch durch das Bayessche Netzwerk unterstützt werden. Dadurch wird es ihnen ermöglicht, auch prozessübergreifende Ursachen-Wirkzusammenhänge aus unterschiedlichen Fachbereichen zu berücksichtigen. Das Bayessche Netzwerk kann gemäß Unterkapitel 4.4 als aggregierte Wissensdatenbank betrachtet werden und dabei helfen zu verifizieren, ob der Datensatz vollständig ist oder weitere Datenquellen einzubinden sind. (KORNAS ET AL. 2019A, S. 381-382)

### Datenverständnis

Daten aus verschiedenen Quellen können eine ungenügende Qualität aufweisen, welche zu Problemen in der weiteren Analyse führen kann (SCHMITT 2020, S. 189). Die Phase des Datenverständnisses (im Englischen „Data Understanding“) ist notwendig, damit der Experte im Detail bewerten kann, ob die selektierten Daten für das vorliegende Analyseziel geeignet sind. Diese Phase wird als explorative Datenanalyse bezeichnet, da sie einer ersten Erkundung

dienen soll (SCHACHT & LANQUILLON 2019, S. 114). Ein wesentliches Forschungsdefizit dieser Phase stellen nach SCHMITT allerdings „praxisgeeignete Instrumente zur Prüfung und Verbesserung der Datenqualität“ dar (SCHMITT 2020, S. 189). Diesem Defizit soll mithilfe der Visual Analytics entgegengewirkt werden. Da für eine Plausibilisierung der Daten auf Vorwissen zurückgegriffen werden muss, bedarf es auch hier einer starken Einbindung der Experten. (KORNAS ET AL. 2019A)

Nach KORNAS ET AL. eignen sich für eine deskriptive Visualisierung von Daten einer komplexen Prozesskette insbesondere Histogramme, Scatterplots und Korrelationsdiagramme (KORNAS ET AL. 2019A, S. 382). Um den Anforderungen während eines Produktionsanlaufes gerecht zu werden, in welchem die Vergleichbarkeit von Produkt- und Prozesseigenschaften gefordert wird, sind multivariate Darstellungsweisen bereitzustellen. Ein Beispiel einer multivariaten Darstellung der Häufigkeitsverteilung und Korrelation zweier Produkt- oder Prozesstypen ist Abbildung 80, Anhang 8.3 zu entnehmen. Wie dabei zu erkennen ist, können statistische Kennwerte unterstützen, Visualisierungen numerisch zu beschreiben (BANKHOFER & VOGEL 2008, S. 27). So wurde der Korrelationskoeffizient nach Bravais-Pearson hinzugezogen, um den linearen Zusammenhang der in Abbildung 80 dargestellten Merkmale zu berechnen. Für den Produkt/Prozesstyp 1 ergibt sich demnach ein Korrelationskoeffizienten von 0.876, für den Produkt/Prozesstyp 2 von 0.799. Für eine detaillierte Beschreibung und Anwendung unterschiedlicher Korrelationskoeffizienten sei auf die Arbeit von CLEFF verwiesen (CLEFF 2015, S. 106).

Um die Qualität einer Korrelation im industriellen Kontext zu beurteilen, ist eine Visualisierung der Daten und deren Interpretation durch einen Prozessexperten zwingend erforderlich. Dass eine Beurteilung rein deskriptiver Zahlen wie bspw. eines Korrelationskoeffizienten nicht hinreichend ist, wird in Abschnitt 2.2.4 Abbildung 11 mithilfe eines exemplarischen Datensatzes nach ANSCOMBE verdeutlicht (ANSCOMBE 1981, S. 17-21). Zu erkennen ist dabei, dass trotz gleicher Korrelationskoeffizienten und gleichem arithmetischen Mittel vier vollkommen unterschiedliche graphische Strukturen vorliegen können. Wie in Abschnitt 2.2.4 beschrieben, repräsentieren solche nicht-kausalen Zusammenhänge Scheinkorrelationen. Eine Interpretation durch Experten hilft dabei, Scheinkorrelationen zu identifizieren oder zu beurteilen, ob kausale Korrelationen von Interesse sind. Denn auch kausale Korrelationen können trivial sein und somit keinen Mehrwert für Experten darstellen (CAO 2012, S. 150). Die in Anhang 8.3, Abbildung 80 dargestellten Werkzeuge der Visual Analytics stellen nach BURDENSKY ET AL. hierfür etablierte, akzeptierte und vertrauenswürdige statistische Methoden dar (BURDENSKY ET AL. 2018, S. 6). Im Weiteren schärfen die Methoden das Verständnis der Experten und unterstützen dadurch die Auslegung neuer Produkte oder Prozesse, was insbesondere in der Prototypenphase eines Produktionsanlaufes einen entscheidenden Mehrwert bietet. Darüber

hinaus eignet sich insbesondere die Korrelationsanalyse, um die in dem Bayesschen Netzwerk abgebildeten Ursachen-Wirkzusammenhänge zu validieren und anzupassen.

### Datenvorbereitung

Die Datenvorbereitung repräsentiert die dritte Phase des Konzepts zur Self-Service Data Analytics (vgl. Abbildung 50). Sie beinhaltet alle Schritte, um den finale Datensatz für die weitere Modellierung vorzubereiten (KESSLER & GÓMEZ 2020, S. 102). Die Schritte dieser Phase lassen sich wie folgt zusammenfassen, wobei ausgewählte Schritte nachfolgend im Detail diskutiert werden (GAROUFALLOU ET AL. 2019, S. 117, SHAEARER 2000, S. 14, SCHACHT & LANQUILLON 2019, S. 114):

- Datenreduktion
- Datennormalisierung
- Imputation fehlender Daten
- Ableitung neuer Merkmale
- Transformation des Datensatzes

Ausgehend von dem Ziel eines Datenanalyseprojektes ist eine Reduktion des zu betrachtenden Datensatzes anhand unterschiedlicher Attribute durchzuführen (vgl. Abbildung 51). Die nachfolgenden Attribute stellen dabei lediglich eine Auswahl möglicher Eingrenzungen dar:

- **Zeitliche Eingrenzung:** Begrenzung eines Datensatzes auf einen zeitlichen Horizont, wie bspw. einen Produktionszeitraum.
- **Produkt- und Prozesseingrenzung:** Begrenzung auf spezifizierte Prozess- oder Produkttypen, wie bspw. die Filterung nach Batteriezellentypen
- **Merkmalseingrenzung:** Begrenzung des Datensatzes auf bestimmte Eigenschaften, wie bspw. verwendete Baugruppen.

Einen weiteren wesentlichen Bestandteil der Datenreinigung stellt die Identifikation von Ausreißern dar. Da hierfür erneut auf das Vorwissen der Experten zurückzugreifen ist, sind auch hier ausgewählte Methoden der Visual Analytics bereitzustellen, wie bspw. das in Anhang 8.3, Abbildung 81 dargestellte Histogramm.

Die Transformation der Daten stellt ebenfalls einen Schritt dar, in welchem auf das Vorwissen der Experten zurückgegriffen werden muss. Mithilfe geeigneter Operatoren können hierbei neue Merkmale generiert werden (vgl. Abbildung 52). Als Beispiel sei die Berechnung einer Zeitstempeldifferenz zu nennen, mithilfe derer die Dauer zwischen zwei qualitätsrelevanten Prozessschritten beschrieben werden kann. Das Bayessche Netzwerk kann die Experten in der Identifikation solcher qualitätsrelevanten Merkmale unterstützen. Liegt das Ziel eines Datenanalyseprojektes bspw. in der Identifikation der Einflüsse auf die Batteriezellenkapazität,

so kann die Inferenz auf Basis des Bayesschen Netzwerkes den Experten bereits erste Hinweise zur Auswahl korrekter Daten geben. (KORNAS ET AL. 2019A, S. 380)




Abbildung 52: Beispiel einer Datentransformation (aus YAO ET AL. 2018, S. 7).

Das Ergebnis der Phase der Datenvorbereitung wird durch einen finalen Datensatz repräsentiert, welcher den Eingang für die darauffolgende Modellierung bildet. Wie Tabelle 4-4 verdeutlicht, lässt sich dieser Datensatz in einer Matrix abbilden. Dabei werden jeder Batteriezelle (charakterisiert durch eine ID-Nummer) Merkmale ( $M_1$  bis  $M_n$ ) zugeordnet. Merkmale repräsentieren dabei Eigenschaften von Prozesskettenelementen eines jeweiligen Prozessschrittes, wie bspw. die verbaute Anodenlänge eines Wickelprozesses.

Tabelle 4-4: Darstellung der finalen Datenmatrix aus Ausgangslage für die Modellierungsphase.

Batteriezelle	Prozessschritt 1			Prozessschritt 2			Prozessschritt 2			...	Prozessschritt n		
	$M_1$	$M_2$	$M_3$	$M_4$	$M_5$	$M_6$	$M_7$	$M_8$	$M_9$	...	...	...	$M_n$
Zell-ID 1													
Zell-ID 2													
...													
Zell-ID n													

### Modellierung, Modellevaluierung und Modelleinsatz

Da Experten in der gleichzeitigen Verarbeitung einer Vielzahl von Variablen limitiert sind, wird neben den genannten Methoden der deskriptiven Statistik, Machine Learning (im Deutschen „maschinelles Lernen“) verwendet, um prozessübergreifende und überlagerte Ursachen-Wirkzusammenhänge zu identifizieren. Während die Phasen der Datenselektion, des Datenverständnisses und der Datenvorbereitung einen manuellen Prozess darstellen, welcher von Experten iterativ zu gestalten ist, liegt der Schwerpunkt des Machine Learning in der Teilautomatisierung des Modellierungsprozesses (SCHACHT & LANQUILLON 2019, S. 114-117). Darauf

aufbauend kann Automated Machine Learning (AutoML) verwendet werden, um ein vollautomatisiertes und simultanes Lernen von Modellen zu erzielen (vgl. YAO ET AL. 2018; ABELE & D'ONOFRIO 2020, S. 53; HUTTER ET AL. 2019, S. 1). Das Vorgehen lehnt sich dabei an das in Abbildung 53 dargestellte Prozessmodell an. (KORNAS ET AL. 2019A, S. 381)

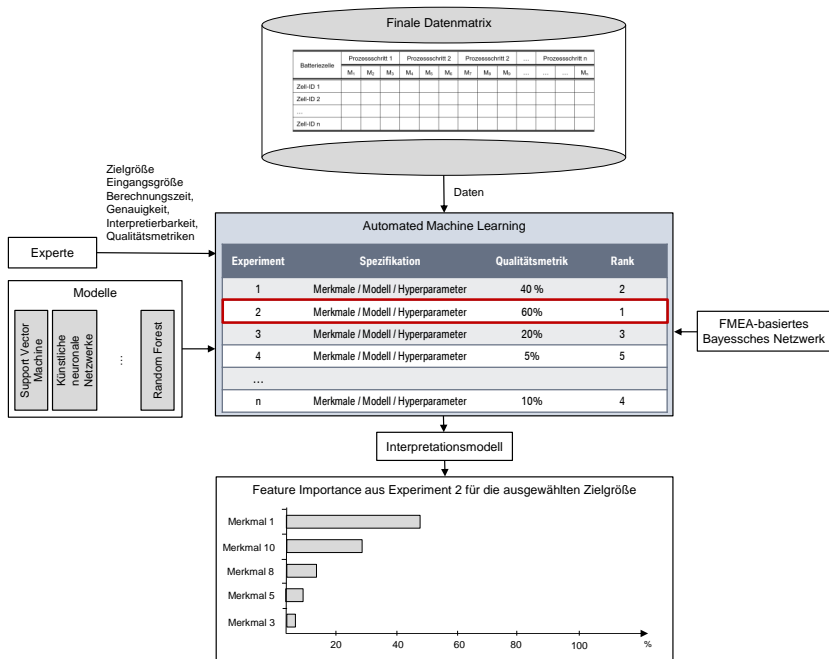


Abbildung 53: Schematische Darstellung des AutoML-Prozessmodells (in Anlehnung an YAO ET AL. 2018, S. 2 und KATZ ET AL. 2016, S. 979).

Die Ausgangslage des AutoML-Prozessmodells bildet die finale Datenmatrix, in welcher die Batteriezellen und dazugehörigen Merkmale der einzelnen Prozessschritte abgebildet werden. Darüber hinaus sind von Experten Randbedingungen zu spezifizieren, welche sich wie folgt zusammenfassen lassen:

- Die **Zielgröße** beschreibt die zu untersuchende Variable einer Modellierung. Sie stellt eines der n Merkmale der Datenmatrix dar und kann bspw. durch die Kapazität einer Batteriezelle repräsentiert werden.



- **Eingangsgrößen** repräsentieren die Variablen, auf deren Basis Modelle trainiert werden. Für eine zielführende Modellierung sind bei der Auswahl der Eingangsgrößen die Einflussbeziehungen der Prozesskette zu berücksichtigen. Dadurch kann sichergestellt werden, dass nur Merkmale einen Eingang der Modellierung bilden, welche aus Sicht des Produktionsflusses die zu analysierende Zielgröße auch tatsächlich beeinflussen. Aufgrund der Vielzahl von Prozessschritten und Prozesskettenelementen kann die Auswahl geeigneter Eingangsgrößen für die Experten eine große Herausforderung darstellen. Deshalb ist sie methodisch zu unterstützen. Eine methodische Unterstützung kann mithilfe des Bayesschen Netzwerkes erzielt werden, welches aufgrund der Eigenschaft gerichteter azyklischer Graphen die Einflussbeziehungen eindeutig abbildet.
- Über die **Berechnungszeit** soll die relative Dauer einer Modellierung spezifiziert werden. Eine Umsetzung kann bspw. über die Anzahl der verwendeten Prozessoren erfolgen.
- Die **Genauigkeit** kann nach MURDOCH ET AL. definiert werden als der Grad, in welchem ein Modell gelernte Beziehungen objektiv erfassen kann (MURDOCH ET AL. 2019, S. 3). Die Genauigkeit lässt sich bspw. über die Modellauswahl oder die Berechnungszeit anpassen. Eine Quantifizierung erfolgt durch ausgewählte Qualitätsmetriken.
- Die **Interpretierbarkeit** beschreibt den Grad, zu dem die Modelle durch Experten plausibilisiert werden können (ESCALANTE ET AL. 2018, S. 6-7). Die Interpretierbarkeit lässt sich durch die Auswahl unterschiedlicher Modelle steuern. (SCHNELL ET AL. 2019, S. 364)
- **Qualitätsmetriken** dienen einer Beurteilung der Modellgüte. So kann bspw. für Regressionsmodelle auf die mittlere quadratische Abweichung (im Englischen MSE für „Mean Square Error“) oder den mittleren absoluten Fehler (im Englischen MAE für „Mean Absolute Error“) zurückgegriffen werden. Für eine Beschreibung unterschiedlicher Metriken sei auf die Arbeit von SHCHERBAKOV ET AL. und CHANG ET AL. verwiesen. (SHCHERBAKOV ET AL. 2013, S. 171 ff.; CHANG ET AL. 2014, S. 132 ff.)

Der Fokus von AutoML liegt, wie Abbildung 53 verdeutlicht, in der Automatisierung und Parallelisierung von Experimenten (FUSI ET AL. 2017, S. 4). Jedes Experiment basiert auf einem Machine-Learning-Modell. Da es nicht nur ein Modell gibt, welches konsistent für alle Datensätze und Analyseziele die besten Resultate erzielt, wird auf unterschiedliche Modelle zurückgegriffen (SCHACHT & LANQUILLON 2019, S. 115). Um die Ergebnisse eines jeden Experimentes zu verbessern, erfolgt eine automatisierte Dimensionsreduzierung. Die Dimensionsreduzierung verfolgt das Ziel, die von den Experten spezifizierten Eingangsgrößen auf

die statistisch relevanten zu verringern (SAMMUT & WEBB 2011, S. 402). Für einen Überblick möglicher Ansätze zu Dimensionsreduzierung sei auf SAUNDERS verwiesen (SAUNDERS 2006, S. 84). Im Weiteren basiert jedes Experiment auch auf einem automatisierten Hyperparametertuning (DÖBEL ET AL. 2018, S. 50 ff.)

Tabelle 4-5 verdeutlicht die differenzierenden Merkmale von AutoML. Es lässt sich zusammenfassen, dass bei traditionellen Verfahren des Machine Learning der Data Scientist eine zentrale Rolle in allen Schritten des Modellierungsprozesses einnimmt, während AutoML eine Vollautomatisierung bietet. So können Maschine-Learning-Methoden ohne umfangreiche Programmierkenntnisse von Experten flexibel angewendet werden. (YAO ET AL. 2018, S. 4)

Tabelle 4-5: Vergleich Traditionelle Verfahren des Machine Learning und AutoML  
(in Anlehnung an YAO ET AL. 2018, S. 4).

Vergleichsaspekte	Traditionelle Verfahren des Machine Learning	AutoML
Dimensionsreduzierung	Auswahl und Durchführung durch Data Scientist.	Automatisiert durch ein Computerprogramm.
Modellauswahl	Auswahl, Anpassung der Modelle sowie Hyperparametertuning durch Data Scientist.	
Hyperparametertuning	Auswahl und Optimierung der Hyperparameter erfolgen durch Data Scientist.	

Simple Modelle, wie bspw. lineare Regressionen oder Entscheidungsbäume, sind für Experten erklärbar und können nach GOSIEWSKA ET AL. als „Glass-Box“ bezeichnet werden (GOSIEWSKA ET AL. 2019, S. 1). Die Interpretation von Machine-Learning-Modellen stellt allerdings eine große Herausforderung dar, um Data Analytics in komplexen Prozessketten wie einer Batterie-zelleproduktion anzuwenden (KORNAS ET AL. 2019A, S. 381; SCHNELL ET AL. 2019, S. 364). Ohne die Verwendung von Interpretationsmöglichkeiten weisen komplexe Machine-Learning-Modelle einen „Black-Box“-Charakter auf, in welchem die Eingangs- und Ausgangsrelationen für Anwender nicht erkennbar sind (MÜLLER ET AL. 2020, S. 190). Eine Möglichkeit zur Interpretation komplexer Machine-Learning-Modelle stellen Feature Importances dar (ELSHAWI ET AL. 2019, S. 1). Diese beschreiben den relativen Einfluss von Eingangsgrößen auf eine ausgewählte Zielgröße und sind in Abbildung 53 als Ergebnis der Modellierung dargestellt (STAU-DER ET AL. 2014, S. 155). Um eine Berechnung von Feature Importances für unterschiedliche Machine-Learning-Modelle zu erzielen, wird auf Interpretationsmodelle zurückgegriffen. LIME repräsentiert bspw. ein Interpretationsmodell, welches den Anspruch erhebt, für alle maschi-nellen Klassifikationen geeignet zu sein. Für eine detaillierte Beschreibung sei auf die Arbeit von RIBEIRO ET AL. verwiesen (RIBEIRO ET AL. 2016).

Es lässt sich zusammenfassen, dass Feature Importances eine zentrale Methode der Self-Service Data Analytics darstellen. Während die Modellierung lediglich der Identifizierung prozessübergreifender Ursachen-Wirkzusammenhänge dient, können mithilfe der Feature Importances die Ergebnisse für Experten interpretierbar dargestellt werden. Die Evaluierung von Feature Importances bedarf, vergleichbar zur Phase des Datenverständnisses, einer Plausibilisierung. Denn auch trotz hoher statistischer Signifikanz muss nicht zwingend eine Relevanz oder Anwendbarkeit für eine Produktion vorliegen (SCHACHT & LANQUILLON 2019, S. 116). Sollten die Feature Importances keine plausiblen Ergebnisse abbilden, so ist durch einen Sprung in eine der vorangehenden Phasen der Self-Service Data Analytics eine Anpassung des Modells möglich. Dies unterstreicht die Notwendigkeit eines flexibel durchführbaren Ansatzes. (KORNAS ET AL. 2019A, S. 380 ff.)

Es sei zu betonen, dass der Schwerpunkt des vorliegenden Abschnittes nicht in Datenvorverarbeitungs- oder Datenanalysemethoden liegt. Vielmehr wird der Fokus auf den konzeptionellen Aufbau eines expertengetriebenen Datenanalyseansatzes gesetzt. Die Schnittstelle der Self-Service Data Analytics im Gesamtkonzept des Qualitätsmanagementsystems (vgl. Abbildung 27) soll deshalb im nachfolgenden Abschnitt verdeutlicht werden.

#### *4.5.2 Synergetische Verknüpfung von experten- und datenbasierten Methoden*

Das Konzept zur Self-Service Data Analytics hat deutlich gemacht, dass die Einbindung von Experten in den Prozess der Datenanalyse einen wesentlichen Hebel darstellt, um einen zielgerichteten und auf die Industrie übertragbaren Wissensgewinn zu fördern. Experten sind eingebunden, um bspw. auf Basis von Vorkenntnissen oder Randbedingungen geeignete Datensätze zu selektieren oder neue Merkmale zu generieren. Sie sind entscheidend für die Plausibilisierung von Ergebnissen, insbesondere während der Phase des Datenverständnisses und der Modellevaluation. Das Bayessche Netzwerk stellt eine wesentliche methodische Unterstützung für diese Phase dar. Es repräsentiert eine Wissensdatenbank mit bereits identifizierten Ursachen-Wirkzusammenhängen, welche den Experten eine prozessübergreifende Betrachtungsweise auf die Produktion ermöglicht. Im Kontext des Gesamtkonzepts eines Qualitätsmanagementsystems (vgl. Abbildung 27) bildet das Bayessche Netzwerk darüber hinaus die zentrale Methode zur Fehler-Ursachen-Analyse und schafft mithilfe fundierter Erkenntnisse aus der Datenanalyse einen entscheidenden Mehrwert.

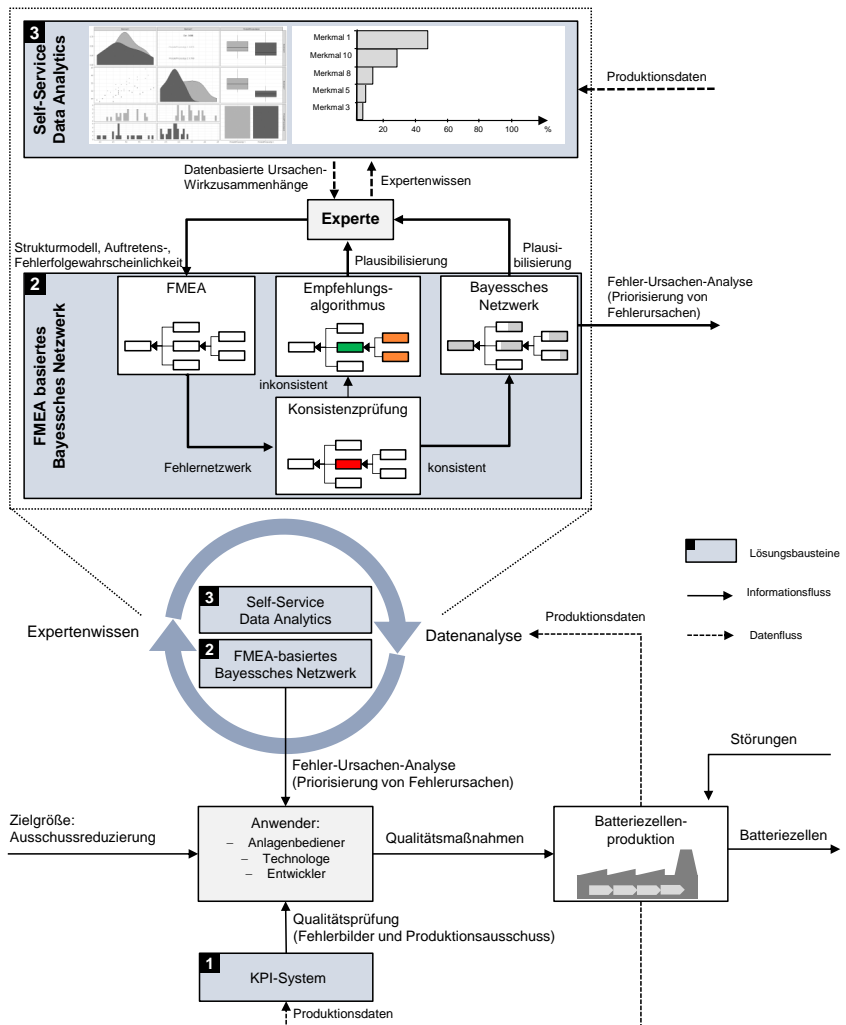


Abbildung 54: Prozessablauf zur synergetischen Verknüpfung der Self-Service Data Analytics und des Bayesschen Netzwerkes.

Die synergetische Verknüpfung der Self-Service Data Analytics und des Bayesschen Netzwerkes sowie die essenzielle Rolle des Experten sollen mithilfe von Abbildung 54 verdeutlicht werden. Demnach ist erkennbar, dass der Experte im Zentrum des Prozessablaufes steht. Er

repräsentiert den Anwender des Bayesschen Netzwerkes sowie der Self-Service Data Analytics. Gemäß Abschnitt 4.1 ist er für den Aufbau einer initialen FMEA zuständig und repräsentiert im Falle von Inkonsistenzen in der Expertenbewertung den Anwender des Empfehlungsalgorithmus. Die hieraus resultierenden Empfehlungen zur Anpassung des Fehlernetzwerkes sind von dem Experten zu plausibilisieren und gegebenenfalls in die FMEA iterativ einzupflegen. Ab Beginn einer Datenaufzeichnung kann der beschriebene Prozess durch die Self-Service Data Analytics unterstützt werden. Unter Verwendung von bspw. Korrelationsanalysen und Feature Importances können somit die von den Experten bewerteten Ursachen-Wirkzusammenhänge validiert und über den Produktionsanlauf hinweg erweitert werden. Auf diese Weise lassen sich auch die Ergebnisse des Empfehlungsalgorithmus plausibilisieren. Das Alleinstellungsmerkmal des Prozessablaufes liegt insbesondere in der synergetischen Verknüpfung von Datenanalysemethoden und Expertenwissen. Demnach ist das Bayessche Netzwerk als aggregierte Wissensdatenbank zu betrachten, in welchem das prozessübergreifende Domänenwissen hinterlegt ist. Es stellt eine zweckmäßige Methode dar, um die Experten bei der Durchführung einer Datenanalyse zu unterstützen. (KORNAS ET AL. 2019A)

#### 4.5.3 Zusammenfassung und kritische Gegenüberstellung der Anforderungen

Die Identifizierung von Ursachen-Wirkzusammenhängen stellt die Voraussetzung einer Fehler-Ursachen-Analyse dar. Die in Abschnitt 4.1 diskutierte Erweiterung einer FMEA repräsentiert eine Möglichkeit, um Ursachen-Wirkzusammenhänge in der frühen Phase eines Produktionsanlaufes expertenbasiert zu erkennen. Als weiterer Ansatz ist ab Beginn der Datenaufzeichnung auf Datenanalysemethoden zurückzugreifen, um Zusammenhänge fundiert nachzuweisen. Ein wesentliches Defizit etablierter Ansätze der Datenanalyse liegt darin, dass die Rolle des Experten und seine Interaktionen mit der Datenanalyse nicht ausreichend genutzt werden. Infolgedessen sind Ergebnisse oftmals in der Industrie nicht anwendbar. Um diesen Defiziten entgegenzuwirken, wurde die Self-Service Data Analytics eingeführt, welche ein expertengestütztes Konzept zur Datenanalyse bildet. Da insbesondere die Phase der Datenvorbereitung durch viele Iterationsschritte charakterisiert ist, welche aus einem intensiven Austausch zwischen Experten und Data Scientist resultieren, stellt die Self-Service Data Analytics eine zweckmäßige Lösung dar. Sie zeichnet sich durch besondere Agilität aus, welche eine iterative und autarke Anpassung in jeder Prozessphase unterstützt.

Ein weiteres Alleinstellungsmerkmal stellt die *methodische Verknüpfung der zentralen Lösungsbausteine (A<sub>41</sub>)* dar, welche eine synergetische Verwendung der Self-Service Data Analytics mit dem Bayesschen Netzwerk ermöglicht. Dies unterstützt eine *kontinuierliche*

*Verbesserung der Produkte und Prozesse (A<sub>42</sub>)* während eines vollständigen Produktionsanlaufes. Im Detail wird dabei das Ziel verfolgt, das Expertenwissen zu nutzen, um die Datenanalyse zu unterstützen. Umgekehrt werden die Datenanalysen verwendet, um das Expertenwissen zu schärfen. Die Anforderung eines *komplementären Erkenntnisgewinns (A<sub>16</sub>)* wird dadurch vollständig erfüllt.

Auch die Anforderung eines durch *Experten gestützten Prozesses der Datenanalyse (A<sub>15</sub>)* wird vollständig erfüllt. Auf Basis innovativer Methoden, wie Visual Analytics oder AutoML ist der Experte in der Lage den Prozess der Datenanalyse eigenständig und agil durchzuführen. Dabei kann er sein Vorwissen nutzen, um Einschränkungen zu berücksichtigen oder Ergebnisse zu plausibilisieren. Eine *Eignung für komplexe Prozessketten (A<sub>13</sub>)* wird dadurch erreicht, dass Machine-Learning-Methoden eine Identifizierung prozessübergreifender Zusammenhänge ermöglichen. Sie repräsentieren darüber hinaus einen Ansatz zur *feldorientierten Untersuchung (A<sub>14</sub>)*. Eine Nachvollziehbarkeit der Modelle und Interpretierbarkeit der Ergebnisse wird zudem mithilfe von Interpretationsmodellen ermöglicht. Mithilfe der flexiblen Auswahl von Datenquellen wird zudem die Anwendbarkeit gefördert.

## 4.6 Implementierung

Das übergeordnete Ziel der vorliegenden Forschungsarbeit liegt in der Entwicklung eines experten- und datenbasierten Qualitätsmanagementsystems, um den Ausschuss in einer Batteriezellenproduktion zu reduzieren (vgl. Abbildung 27). Das Konzeptbild der Arbeit lehnt sich an einen Qualitätsregelkreis an und basiert im Wesentlichen auf den drei bisher thematisierten zentralen Lösungsbausteinen:

- KPI-System,
- Bayessches Netzwerk und
- Self-Service Data Analytics.

Um eine kontinuierliche Produkt- und Prozessoptimierung während eines vollständigen Produktionsanlaufes zu erzielen, sind die drei Lösungsbausteine zu einem nachvollziehbaren Gesamtsystem zu verknüpfen und für die Fertigungsebene, die Fertigungsleitebene und das Entwicklungspersonal bereitzustellen. Aus diesem Grund wird in diesem Unterkapitel die prototypische Implementierung des Qualitätsmanagementsystems diskutiert. Zusammen mit der in Kapitel 5 beschriebenen, exemplarischen Anwendung soll dadurch der Nachweis über die Durchführbarkeit des entwickelten Konzepts erbracht werden.

Die Architektur der prototypischen Implementierung ist Abbildung 55 zu entnehmen.



Demnach ist eine Strukturierung auf drei Ebenen erkennbar, die sich wie folgt zusammenfassen lässt:

- Die **Datenebene** zeigt das Speicherungs-, Aufbereitungs-, und Bereitstellungskonzept der zu verwendeten Daten auf.
- Die **Logikebene** greift auf die Daten zu und umfasst die Implementierung der diskutierten zentralen Lösungsbausteine.
- Die **Visualisierungsebene** stellt die grafische Benutzeroberfläche dar, um eine Interaktion mit dem Anwender zu ermöglichen.

Nachfolgend wird die Implementierung der genannten Ebenen anhand der in Abbildung 55 dargestellten Elemente im Detail diskutiert.

#### 4.6.1 Datenebene

Das **Data Warehouse** bildet eine Schlüsselkomponente der Datenebene. Wie Abbildung 55 zu entnehmen ist, werden hierbei heterogenen Datenquellen aggregiert und in einer geeigneten Struktur für eine weitere Analyse bereitgestellt. Nach JUNG & WINTER ist ein Data Warehouse definiert als „[...] subjektorientierte, integrierte und zeitorientierte [...] Sammlung von Daten“ (JUNG & WINTER 2000, S. 4). In Bezug auf die Batteriezellenproduktion liegt das Ziel des Data Warehouse darin, eine prozessübergreifende Sicht einer jeden Batteriezelle zu erhalten. Deshalb lehnt sich die Struktur an der in Tabelle 4-4 aufgezeigten Datenmatrix an. Jede Batteriezelle (charakterisiert durch eine ID-Nummer) entspricht dabei einer Zeile der Matrix. Die Eigenschaften von Prozesskettenelementen eines jeden Prozessschrittes, wie bspw. die verbaute Anodenlänge eines Wickelprozesses, werden in den Spalten abgebildet. Eine solche Datenstruktur erhöht die Interpretierbarkeit und vereinfacht die in Abschnitt 4.6.2 diskutierte Entwicklung der Logikebene. Die technische Umsetzung des Data Warehouse erfolgt mithilfe von *Microsoft Azure Cloud* auf Basis von SQL. Ein Schwerpunkt liegt dabei in der Ansprechgeschwindigkeit und der Verfügbarkeit der Datenbank, sodass eine dynamische Nutzung gewährleistet werden kann, welche bspw. Ad-hoc-Anfragen ermöglicht. Ein solches Datensicherungskonzept kann als „Hot Storage“ bezeichnet werden. Die Bezeichnung soll dabei die Echtzeitanwendung der Datenbank unterstreichen. Im Gegensatz dazu beschreibt ein „Cold Storage“ die Speicherung von Daten, auf welche selten zugegriffen wird (LEVANDOSKI ET AL. 2013 - 2013, S. 27). Im Weiteren sei für detaillierte Informationen zu Bereitstellungs- und Integrationskonzepten von Datenbank im Kontext von Fertigungsprozessen auf die Arbeit von GRÖGER verwiesen (GRÖGER 2015).



Einen Eingang in das Data Warehouse bilden zunächst **Begin-of-Line-Daten**. Diese beschreiben Eingangsproduktmerkmalen, welche bspw. aus einer chemischen Analyse resultieren. Die qualitätsrelevanten Informationen werden auf Basis eines ETL-Prozesses (englisch für „Extract, Transform, Load“) aus vorliegenden XLS-Dateien entnommen, transformiert und in dem Data Warehouse hinterlegt.

Auch die Daten der **Produktion**, welche die Eigenschaften von Prozesskettenelementen sowie Informationen der technischen Gebäudeausrüstung abbilden, werden mithilfe eines ETL-Prozesses verarbeitet. Die Produktionsdaten liegen in einem Data Lake vor, welcher im Gegensatz zum Data Warehouse, eine heterogene Datenbankstruktur aufweist (JOHN & MISRA 2017, S. 43). Der Data Lake basiert auf *Apache Hadoop*, einer Softwaretechnik der Firma *Hortonworks*. Die lückenlose Rückverfolgbarkeit der Produktionshistorie mithilfe eines ETL-Prozesses stellt eine besondere Herausforderung der Batteriezellenproduktion dar. Dies kann damit begründet werden, dass sich die Batteriezellenproduktion durch konvergierende und divergierende Materialströme auszeichnet und diskontinuierliche sowie kontinuierliche Produktionsverfahren beinhaltet (THOMITZEK ET AL. 2018, S. 347; SCHÖNEMANN 2017, S. 68). Die Herausforderungen sollen mithilfe von Abbildung 56 verdeutlicht werden.

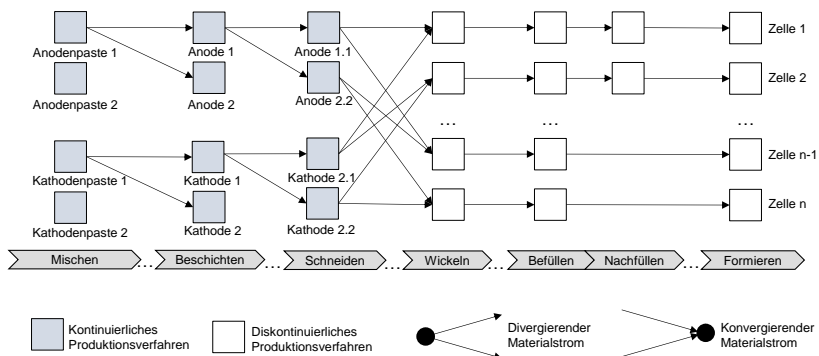


Abbildung 56: Schematische Abbildung des Materialstroms einer Batteriezellenproduktion (in Anlehnung an SCHÖNEMANN 2017, S. 70).

Demnach spiegelt der Prozess des Mischens ein diskontinuierliches Produktionsverfahren wider. Die hierbei hergestellten Pasten werden auf unterschiedliche Beschichtungsanlagen verteilt, was einem divergierenden Materialstrom entspricht. Der Beschichtungsprozess stellt ein kontinuierliches Produktionsverfahren dar. Für eine Weiterverarbeitung erfolgt ein Zuschnei-

den der hierbei hergestellten Elektrodenbahnen in Tochterelektroden. Aufgrund von Qualitätsschwankungen im Misch- und Beschichtungsprozess ist die Zuordnung der Tochterelektroden zur Elektrodenbahn von großer Relevanz. Die Zuordnung wird allerdings durch die komplexen Materialströme erschwert. Eine weitere Herausforderung in der Auslegung eines ETL-Prozesses können Variationen im Produktionsablauf darstellen, wie am Beispiel des Nachfüllprozesses verdeutlicht werden soll. Es lässt sich ableiten, dass die in der Batteriezellenproduktion vorliegenden konvergierender und divergierender Materialströme sowie diskontinuierliche und kontinuierliche Produktionsverfahren zu starken Variationen in der Produktqualität führen können. Um die qualitätsrelevanten Einflüsse des Fertigungsprozesses im Rahmen einer Datenanalyse zu identifizieren, ist eine lückenlose Rückverfolgbarkeit mithilfe eines geeigneten ETL-Prozesses zwingend erforderlich.

Aufgrund der Vielzahl an qualitätsrelevanten Prozesskettenelementen ist allerdings davon auszugehen, dass mögliche Fehlerbilder auf Basis der Daten nicht vollständig erfasst werden können. Um die Reichweite in der Qualitätsprüfung zu vergrößern, kann, wie in Unterkapitel 4.3 beschrieben, auf **subjektive Qualitätsprüfungen** zurückgegriffen werden. Eine vereinheitlichte Fehlerbeschreibung ist dabei zwingend erforderlich, damit die erfassten Informationen der subjektiven Qualitätsprüfung auch für eine Datenanalyse verwendet werden können. Die Fehlerbeschreibung erfolgt deshalb mithilfe eines standardisierten Dokumentes, welches Tabelle 4-6 entnommen werden kann. Anhand definierter Kriterien können funktionale, prozessuale oder konstruktive Fehler eindeutig beschrieben werden. Die Strukturierung unterstützt die maschinelle Lesbarkeit, sodass eine Anbindung an das Data Warehouse gefördert und eine Verarbeitung der Informationen im Rahmen der Datenanalyse ermöglicht wird.

Tabelle 4-6: Vereinheitlichte Fehlerbeschreibung für subjektive Prüfmethoden.

Zellen-ID	Zeitpunkt	Fehlerbezeichnung	Fehlerkomponente	Fehlerort	Fehlerbeschreibung
...	...	Lithium-Plating	Anode	Mittig der Elektrodenbahn	Regelmäßiges Lithium-Plating
...	...	Lithium-Plating	Anode	Oberer Randbereich	Vereinzelt Lithium-Plating
...	...	Lose Ableiterspangen	Deckelbaugruppe	Anodenseite	Lösen der Ableiterspangen von Trägerfolie
...	...	Partikelverschmutzung	Zellkörper	Kathodenbahn	Vereinzelte metallische Partikel

**End-of-Line-Daten** resultieren aus dem Vorladen (im Englischen als Precharge bezeichnet), der Formierung oder der Zyklisierung. Das Vorladen und die Formierung stellen den erste

Lade- und Entladezyklus dar, in welchem die elektrochemischen Eigenschaften von Batteriezellen ausgebildet werden (YOSHIO 2009, S. 192 ff.). Das Zyklieren dient der Bewertung der Lebensdauer (LEUTHNER 2013, S. 18). In beiden Fällen liegt eine kontinuierliche Messung der Spannung und des Stromes über den Zeitverlauf vor. Auch hier ist ein umfangreicher ETL-Prozess notwendig, um aus den Kurvenverläufen die qualitätsrelevanten Informationen einer Batteriezelle zu ermitteln. Zu diesen zählen bspw. Kapazität, Spannung, innerer Widerstand oder auch ein möglicher Spannungsabfall, welcher während der Zyklierung identifiziert werden kann (SCHMIDT 2013, S. 66 ff., KAMPKER ET AL. 2013, S. 245).

Das **Produkt- und Prozessmodell** ist als eine strukturierte Datenablage produkt- und prozessspezifischer Informationen zu betrachten. Es bildet einen Eingang in das KPI-System sowie die Self-Service Data Analytics. Die technische Umsetzung erfolgt ebenfalls mithilfe einer *Microsoft Azure Cloud*.

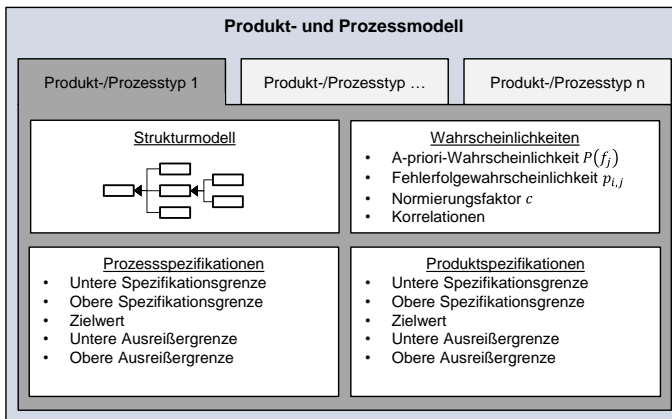


Abbildung 57: Produkt- und Prozessmodell der prototypischen Implementierung.

Das Produkt- und Prozessmodell beinhaltet, wie Abbildung 57 verdeutlicht, zum einen das aus der FMEA resultierende Fehlernetzwerk, in welchem die Ursachen-Wirkzusammenhänge aller qualitätsrelevanten Prozesskettenelemente abgebildet sind (vgl. Abschnitt 4.1). Darüber hinaus werden A-priori-Wahrscheinlichkeiten  $P(f_i)$  und Fehlerfolgswahrscheinlichkeiten  $p_{i,j}$  abgelegt, mithilfe derer ein Bayessches Netzwerk vollständig beschrieben werden kann. Durch den Vektor  $c$  lässt sich die Sicherheit einer Expertenaussage bei der Bewertung der Wahrscheinlichkeiten abbilden. Dieser Faktor ist entscheidend für die zielorientierte Bestimmung eines konsistenten Netzwerkes auf Basis der Optimierungsfunktion (vgl. Abschnitt 4.4.5). Die

Produktspezifikationen sind strukturiert abzulegen, da sie einen Eingang für das KPI-System bilden. Die Korrelationen werden dabei genutzt, um multivariate Prozessfähigkeitsindizes zu berechnen (vgl. Abschnitt 4.3.2). Die Betrachtung eines vollständigen Produktionsanlaufes fordert im Weiteren eine generische Auslegung des Produkt- und Prozessmodells. Aus diesem Grund werden hier unterschiedliche Produkt- und Prozesstypen berücksichtigt.

Die Durchführung der FMEA erfolgt mithilfe der Software *APIS IQ FMEA*. Das Tool zeichnet sich durch hohe Flexibilität und Praxistauglichkeit aus, was eine Modellierung komplexer Prozessketten unterstützt (WERDICH 2012, S. 114). Darüber hinaus können die Ergebnisse der **FMEA-Bewertung** im XML-Dateiformat (Extensible Markup Language) abgelegt werden. XML-Dateien stellen hierarchische Strukturen in Textformaten dar (STAUEMEYER 2007, S. 161). Mithilfe eines ETL-Prozesses werden die zum Aufbau eines Bayesschen Netzwerkes benötigten Informationen aus der XML-Datei extrahiert. Die Extraktion bezieht sich im Detail auf:

- die einzelnen Prozesskettenelemente und deren Ursachen-Wirkzusammenhänge
- die Bewertungskennzahlen der Auftretenswahrscheinlichkeit  $W(f_j)$
- die Fehlerfolgswahrscheinlichkeit  $p_{i,j}$ .

Da, wie in Abschnitt 4.1 beschrieben, die Kennzahl der Auftretenswahrscheinlichkeit  $W(f_j)$  in eine A-priori-Wahrscheinlichkeit  $P(f_i)$  zu übersetzen ist, wird zudem auf eine **Übersetzungstabelle** zurückgegriffen. Inhaltlich ist diese mit Tabelle 4-3 gleichzusetzen.

Einen weiteren Eingang in das Produkt- und Prozessmodell bilden **Produkt- und Prozessspezifikationen**. Wie in Abschnitt 4.5.1 thematisiert, kann die Bestimmung von Spezifikationsgrenzen oder Ausreißern mithilfe ausgewählter Methoden der Visual Analytics in der Phase des Datenverständnisses unterstützt werden. Die Produkt- und Prozessspezifikationen resultieren somit aus der Self-Service Data Analytics.

Damit die im Baysschen Netzwerk identifizierten Ursachen-Wirkzusammenhänge synergetisch mit der Datenanalyse genutzt werden können, muss gewährleistet sein, dass die Bezeichnungen von Prozesskettenelementen und deren Eigenschaften einheitlich sind. Erst dadurch kann eine zielführende Verknüpfung daten- und expertenbasierter Ansätze erfolgen. Aus diesem Grund wird auf eine **Nomenklatur der Prozesskettenelemente** zurückgegriffen, in welcher die Bezeichnungen von Prozesskettenelementen festgelegt sind.

Wie in Abschnitt 4.6.2 thematisiert wird, beinhaltet die prototypische Implementierung neben der Umsetzung der zentralen Lösungsbausteine auch eine Produktionsübersicht. Um die Praxistauglichkeit der Produktionsübersicht für die Anwender zu fördern, können unterschiedliche **Nutzerprofile** mithilfe einer XLS-Datei frei konfiguriert werden.

Die **Produktionsplanungsübersicht** dient der operativen Gestaltung des gesamten Produktionsprozesses einer Batteriezellenfertigung. Die darin enthalten Informationen bilden einen Eingang für die Produktionsübersicht und werden genutzt, um bspw. Ausschüsse an den einzelnen Prozesskettenabschnitten zu bestimmen. Die Inhalte dieser Liste lassen sich wie folgt zusammenfassen:

- Auftragsübersicht (Sollwert der herzustellenden Produkte)
- Spezifizierung der Prozessschritte (Abbildung des Materialflusses und Beschreibung der Prozesse)
- Projektbezeichnungen (Spezifizierung von Chargen, welche bspw. im Rahmen einer Prototypenproduktion hergestellt werden).

#### 4.6.2 Logik- und Visualisierungsebene

Im Zentrum der Logikebene steht die Verarbeitung der beschriebenen Daten mithilfe der entwickelten Lösungsbausteine. Aufbauend auf der Logikebene repräsentiert die Visualisierungsebene den Benutzerzugriff auf die Lösungsbausteine. Die Implementierung der Logik- und Visualisierungsebene erfolgt mithilfe der Open-Source-Programmiersprache *R*. Im Folgenden werden die wesentlichen Eigenschaften und Schwerpunkte der Programmiersprache dargestellt:

- Programmierparadigma: Die Programmiersprache ist auf statistische Problemstellungen ausgerichtet (OHRI 2018, S. 9). Dies spiegelt sich in den zahlreichen verfügbaren Paketen sowie in der Programmier- und Datenstruktur wider (PATHAK 2014, S. 2). Dadurch wird eine Implementierung der geforderten Methoden, wie bspw. Bayesscher Netzwerke, begünstigt.
- Anbindung: Es wird eine Vielzahl von Schnittstellen zu anderer Software bzw. anderen Dateiformaten und Datenbanken bereitgestellt. Das ermöglicht den Zugriff auf die erwähnte *Microsoft Azure Cloud*, XLS- und XLM-Dateien. (GLEICH ET AL. 2017, S. 175)
- Datenanalyse: Es lassen sich verschiedene deskriptive und Machine-Learning-Methoden implementieren (HOLLAND & KARTER 2019, S. 8).
- Visualisierungen: Es wird eine schnelle und flexible Erstellung von Grafiken ermöglicht. So lassen sich auch komplexe Zusammenhänge, wie bspw. ein gerichteter azyklischer Graph eines Bayesschen Netzwerkes, mithilfe geeigneter Pakete abbilden (vgl. WICKHAM 2016). Darüber hinaus unterstützt *R* die Erstellung und Erweiterung multivariater Darstellungen, welche bspw. für das KPI-System oder die Self-Service Data

Analytics gefordert werden (HOLLAND & KARTER 2019, S. 9). Es lassen sich insbesondere mithilfe des Paketes *Shiny* interaktive, responsive und webbasierte Visualisierungen programmieren (SIEVERT 2020, S. 17).

Die in Abbildung 55 dargestellten Elemente der Logik- und Visualisierungsebene sowie deren Verknüpfungen zur Datenebene werden nachfolgend im Detail erläutert.

Um der Anforderung an einen Produktionsanlauf gerecht zu werden, berücksichtigt das **KPI-System** unterschiedliche Losgrößen. Während die Produktion im Labormaßstab oder der Prototypenbau einer Batteriezellenfertigung durch kleine Stückzahlen charakterisiert ist, zielt eine Pilotlinie darauf ab, die Prozessfähigkeit eines spezifizierten Zelldesigns mithilfe größerer Stückzahlen nachzuweisen. Eine Differenzierung der unterschiedlichen Losgrößen erfolgt in den Registern „Betrachtungsumfang Batteriezelle“, „Betrachtungsumfang Charge“ und „Multivariates Kennzahlensystem“. Abbildung 58, Abbildung 59 und Abbildung 60 bilden die prototypische Implementierung der genannten Register mithilfe des R-Paketes *Shiny* ab.

Im **Betrachtungsumfang Batteriezelle** erfolgt eine Beurteilung einzelner Produkte auf Basis gemessener Eigenschaften. In Abbildung 58 ist die prototypische Implementierung des Registers dargestellt. Es wird ein Ausschnitt einer Batteriezellenproduktion abgebildet, welchem die absoluten Werte der jeweiligen Eigenschaften eines Prozessschrittes zu entnehmen sind. Darüber hinaus können Referenzwerte von bspw. Absicherungskampagnen genutzt werden, um eine Vergleichbarkeit zu ermöglichen.

30 - Jelly Roll pressen

🕒 2018-06-05 13:23:29

Prozesskettenelement und Eigenschaft	Wert	Mittelwert. Ref	Std. Ref.
Pressen - Maximalkraft vorwärts [kN]	7.78	7.686	0.26289
Pressen - Jelly Roll Enddicke [mm]	9.917	9.823	0.046688

50 - HiPo Test

Abbildung 58: Ausschnitt der prototypischen Implementierung für den Betrachtungsumfang einzelner Batteriezellen.

Sofern eine Charge von Batteriezellen vorliegt, kann mithilfe der in Abschnitt 4.3.1 diskutierten univariaten Prozessfähigkeitsindizes im Register **Betrachtungsumfang Charge** eine statistisch signifikante Aussage über die Qualität getroffen werden. Wie in Abbildung 59 dargestellt, wird bspw. der  $c_{pk}$  für den Prozessschritt „Jelly Roll pressen“ auf Basis von 46 Batteriezellen berechnet. Für ausgewählte Eigenschaften kann eine Bewertung auch auf Basis des totalen kritischen Prozessfähigkeitsindex  $C_{pmk}$  erfolgen, welcher ein kontinuierliches Qualitätsverständnis widerspiegelt.

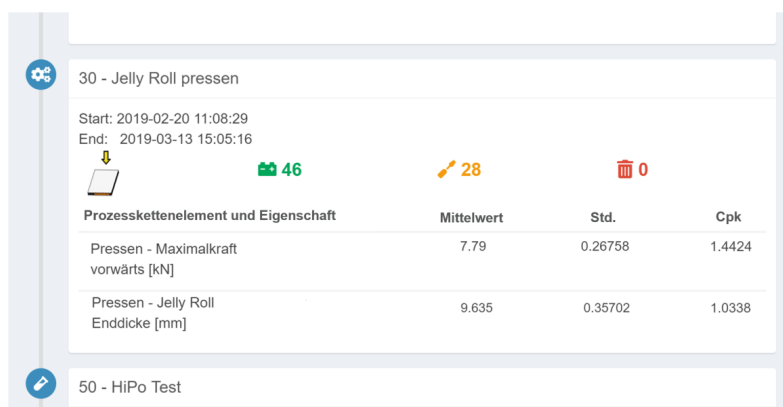


Abbildung 59: Ausschnitt der prototypischen Implementierung für den Betrachtungsumfang einer Charge.

Das **multivariate Kennzahlensystem** aus Abschnitt 4.3.2 erlaubt Prozessketten mit einer Vielzahl an Ursachen-Wirkzusammenhängen aggregiert darzustellen. Mithilfe der Abbildung 60 soll das Prinzip des Kennzahlensystems verdeutlicht werden. Zu erkennen sind dabei die Einflüsse auf das Gesamtgewicht der Batteriezellen. Mithilfe von Pfeilen werden die Beziehungen zwischen den betrachteten Elementen aufgezeigt. Diese kaskadenähnliche Darstellungsform ermöglicht eine aggregierte Abbildung der qualitätsrelevanten Eigenschaften. In dem dargestellten Beispiel wird auf die Darstellung konkreter Werte der einzelnen Prozessfähigkeitsindizes verzichtet. Eine Anwendung der Methode und eine Diskussion der Prozessfähigkeitsindizes im Kontext der Batteriezellenproduktion ist der Arbeit von KORNAS ET AL. zu entnehmen (KORNAS ET AL. 2019B, S. 79-80). Es sei hervorzuheben, dass die Methode die Kenntnis über Korrelationen zwischen Prozesskettenelementen voraussetzt und sich deshalb ausschließlich für einen fortgeschrittenen Produktionsanlauf eignet, in welchem eine hohe Datenqualität vorliegt. Die zum Aufbau des Kennzahlensystems benötigten Korrelationen und

Toleranzgrenzen sind im Produkt- und Prozessmodell hinterlegt. Zur kontinuierlichen Überwachung der Prozessfähigkeitsindizes im Betrachtungsumfang der Chargen oder des multivariaten Kennzahlensystems werden im Rahmen der prototypischen Implementierung auch Qualitätsregelkarten bereitgestellt.

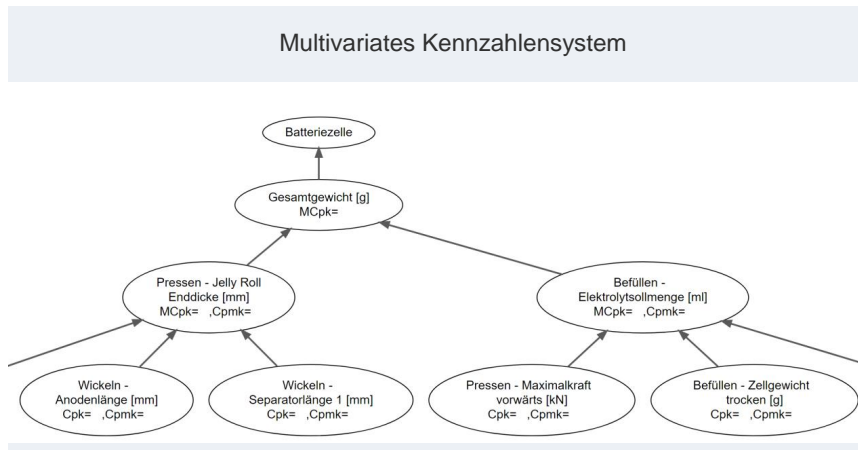


Abbildung 60: Ausschnitt eines multivariaten Kennzahlensystems in Anlehnung an

KORNAS ET AL. 2019B, S. 80.

Das auf der **FMEA-basierte Bayessche Netzwerk** dient einer zielorientierten **Fehler-Ursachen-Analyse**. Inferenzen stellen ein wesentliches Alleinstellungsmerkmal dieser Methode dar. Mithilfe von Inferenzen lassen sich Fehlerursachen unter Berücksichtigung identifizierter Fehlerbilder priorisieren. In dieser Priorisierung liegen auch die in Abschnitt 4.4.6 diskutierten unbekannten Ursachen vor, welche auf Basis von Leak-Nodes quantifiziert werden können. Es sei hervorzuheben, dass die Bayessche Statistik neben dem Rückschluss von Wirkungen auf Ursachen auch den Rückschluss von Ursachen auf Wirkungen ermöglicht. Ausgehend von identifizierten Fehlerbildern kann so eine Priorisierung der Fehlerauswirkungen errechnet werden. Die prototypische Implementierung der Fehler-Ursachen-Analyse ist Abbildung 61 und Abbildung 63 zu entnehmen. Betrachtet wird hierbei eine Batteriezeile, welche den Fehler „Heliumdichtigkeitstest – Leckrate ist zu hoch“ aufweist. In dem dargelegten Beispiel ist darüber hinaus bekannt, dass der Fehler „Heliumdichtigkeitstest – Terminals sind undicht“ nicht aufgetreten ist. Diese Information stellt eine weitere Evidenz im Bayesschen Netzwerk dar. Auf Basis des Fehlerbildes und der Evidenz erfolgt eine automatisierte Inferenzdurchführung, welche



eine Priorisierung von Fehlerursachen und Fehlerauswirkungen liefert. Wie in Abbildung 61 dargestellt, werden hierbei auch die unbekannten Ursachen errechnet. Diese repräsentieren eine mathematisch quantifizierbare Erkenntnislücke. Um die Berechnungszeit der Inferenzdurchführung zu reduzieren und somit die Anwendbarkeit zu fördern, wird in der prototypischen Implementierung ein Simulationsansatz auf Basis des Likelihood-Weighting-Algorithmus verwendet (vgl. Abschnitt 4.4.4). Die Genauigkeit der Ergebnisse sowie die Dauer der Berechnung sind dabei skalierbar und lassen sich über die Anzahl an Simulationsdurchgängen steuern (KIRCHHOF ET AL. 2020).

**Fehler-Ursachen-Analyse**

Batteriezellen-ID (optional):

Diese Fehler sind aufgetreten:

Heliumdichtigkeitstest - Leckrate ist zu hoch

Diese Fehler sind nicht aufgetreten:

Heliumdichtigkeitstest - Terminals sind undicht

**Priorisierung von Fehlerursachen:**

Ursachen-wahrscheinl.	Ebene	Ursache	Prozesskettenelement der Ursache
50.73%	1	Heliumdichtigkeitstest - Berstmembran ist undicht	Heliumdichtigkeitstest - Unversehrtheit Zelle
27.60%	1	Heliumdichtigkeitstest - Unbekannte Ursache von Leckrate ist zu hoch	Heliumdichtigkeitstest - Lecktest Leckrate
17.63%	1	Cap/Can-Schweißen - Schweissnaht ist undicht	Cap/Can-Schweißen - Schweissnaht
0.80%	1	Heliumdichtigkeitstest - Helium vom vorherigen Prüfvorgang ist noch im Auslass vorhanden	Heliumdichtigkeitstest - Anlagenunversehrtheit

**Priorisierung von Fehlerauswirkungen:**

Auswirkungs-wahrscheinl.	Ebene	Auswirkung	Prozesskettenelement der Auswirkung
46.74%	1	Heliumdichtigkeitstest - Berstmembran ist undicht	Heliumdichtigkeitstest - Unversehrtheit Zelle
28.35%	1	Heliumdichtigkeitstest - Unbekannte Ursache von Leckrate ist zu hoch	Heliumdichtigkeitstest - Lecktest Leckrate
18.85%	1	Cap/Can-Schweißen - Schweissnaht ist undicht	Cap/Can-Schweißen - Schweissnaht
0.27%	1	Heliumdichtigkeitstest - Helium vom vorherigen Prüfvorgang ist noch im Auslass vorhanden	Heliumdichtigkeitstest - Anlagenunversehrtheit

Previous 1 Next

Previous 1 2 Next

Abbildung 61: Prototypische Implementierung der Fehler-Ursachen Analyse (KIRCHHOF ET AL. 2020).

Durch die in Abbildung 61 beschriebenen Ebenen (vgl. Spalte 2) wird die Ausprägungsform einer Ursache oder Wirkung beschrieben. Eine Ausprägungsform der Ebene 1 stellt gemäß Abbildung 62 einen direkten Ursachen-Wirkzusammenhang dar. Durch die Ebenenanzahl 2, 3, etc. wird erkenntlich gemacht, dass Wirkungen oder Ursachen eine prozessübergreifende Ausprägungsform besitzen. Möchte ein Experte bspw. die direkten Auswirkungen eines Fehlers angezeigt bekommen, um proaktiv in den nächsten Prozessschritt einzugreifen, kann er hierfür die im Prototypen implementierte Filterfunktion verwenden.




Abbildung 62: Ausprägungsformen von Ursachen-Wirkzusammenhängen

Im Weiteren ist in der prototypischen Implementierung auch eine Visualisierung des Bayesschen Netzwerkes vorhanden. Für das zuvor beschriebene Beispiel ergibt sich der, in Abbildung 63 dargestellte gerichtete azyklische Graph. Aus Gründen der Übersichtlichkeit sind in dem Graphen lediglich die direkten Ursachen und Wirkungen mit der Ausprägungsform der Ebene 1 abgebildet.

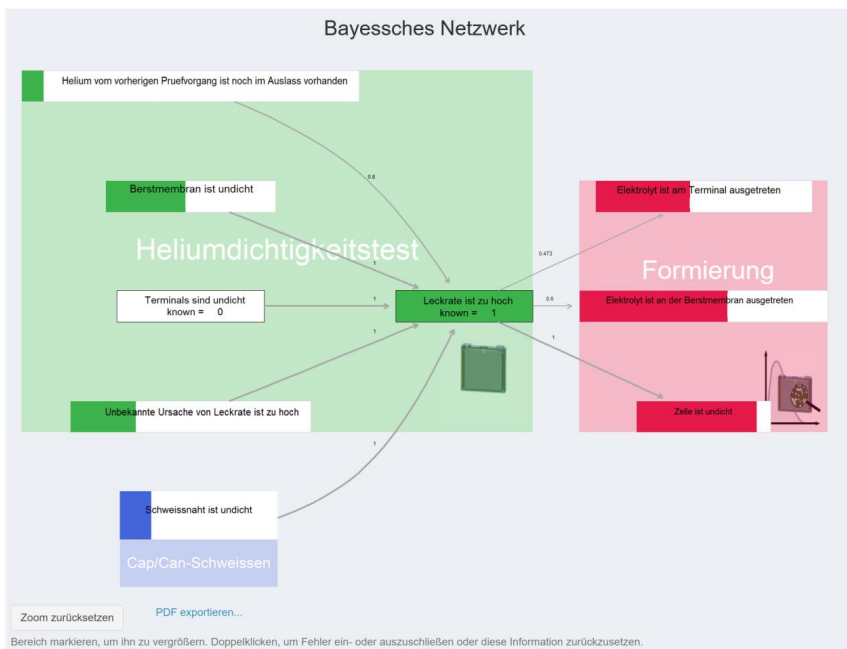


Abbildung 63: Prototypische Implementierung eines visualisierten Bayesschen Netzwerkes.

In der prototypischen Implementierung werden mehrere interaktive Möglichkeiten bereitgestellt, um Fehlerbilder und Evidenzen zu selektieren. Eine Dropdown-Liste bietet die Option der manuellen Eingabe. Darüber hinaus kann ein schrittweises Ergänzen von Evidenzen über die Aus- oder Abwahl der angezeigten Ursachen und Wirkungen erfolgen. Eine Aus- oder Abwahl kann dabei direkt im Bayesschen Netzwerk (vgl. Abbildung 63) oder auf Basis der Einträge priorisierter Fehlerursachen bzw. -wirkungen stattfinden (vgl. grünes Häkchen bzw. rotes Kreuz in Abbildung 61). Auf diese Weise kann der Detailgrad eines Fehlers, ähnlich zu einem Drilldown, erhöht werden (vgl. VMDA 66412-1). Die beschriebenen Möglichkeiten unterstützen einen responsiven Aufbau Bayesscher Netzwerke und fördern den Verständnisgewinn. Insbesondere bei komplexen Fehlernetzwerken werden fach- und prozessübergreifende Ursachen-Wirkzusammenhänge für Anwender verdeutlicht. Eine manuelle Auswahl von Fehlerbildern und Evidenzen durch Experten ist insbesondere für die Anfangsphase eines Produktionsanlaufes bereitzustellen, in welcher aufgrund unzureichender Daten nur subjektive Prüfmethoden vorliegen. Mit Beginn einer Datenaufzeichnung können die im KPI-System identifizierten Fehlerbilder und Evidenzen genutzt werden, um ein Bayessches Netzwerk für ausgewählte Batteriezellen-IDs automatisch aufzubauen.

Es sei zu ergänzen, dass bei dem Aufbau des Bayesschen Netzwerkes auch zwangsläufig eine Konsistenzprüfung stattfindet. Sollten Inkonsistenzen im Bayesschen Netzwerk vorzufinden sein, ist auf Basis des implementierten **Empfehlungsalgorithmus** eine Anpassung durchzuführen.

Um neben dem Baysschen Netzwerk, welches einen expertenbasierten Ansatz darstellt, fundierte Erkenntnisse über Ursachen-Wirkzusammenhänge auf Basis einer Datenanalyse zu erhalten, kann auf die **Self-Service Data Analytics** zurückgegriffen werden. Die Grundlage der Self-Service Data Analytics bildet das Data Warehouse, mithilfe dessen ein Zugriff auf alle qualitätsrelevanten Informationen ermöglicht wird. Die einzelnen Phasen des Self-Service Data Analytics spiegeln sich in den Registern der Visualisierungsebene wider. Die **Datenselektion** dient einer ersten Eingrenzung des Datensatzes und erfolgt mithilfe einer geeigneten Schnittstelle am Data Warehouse. In der darauffolgenden Phase des **Datenverständnisses** stehen Methoden der Visual Analytics im Vordergrund. Der Anlauf einer Batteriezellenproduktion fordert die Vergleichbarkeit von Produkt- und Prozesseigenschaften. Um dem gerecht zu werden, umfasst die prototypische Implementierung eine Vielzahl multivariater Darstellungen. Abbildung 64 stellt exemplarisch eine Korrelationsanalyse zweier Produkt- bzw. Prozesstypen dar. Produkt- und Prozesstypen können anhand unterschiedlicher Filterkriterien spezifiziert werden. Zu diesen zählen Projektbezeichnung, chemische Eigenschaften und Herstellungszeitpunkt.



Abbildung 64: Prototypische Implementierung einer Korrelationsanalyse als Teil der Phase des Datenverständnisses.

Die **Datenvorbereitung** repräsentiert das dritte Register der Self-Service Data Analytics und beinhaltet alle Schritte, um den finale Datensatz für die weitere Modellierung vorzubereiten. In dem Schritt der Datentransformation lassen sich bspw. neue Merkmale auf Basis des Expertenwissens generieren. Des Weiteren wird, wie in Abbildung 65 dargestellt, ein interaktives

Histogramm bereitgestellt, mithilfe dessen Ausreißer, Spezifikationsgrenzen und Zielwerte bestimmt werden können. Die Spezifikationsgrenzen und Zielwerte bilden einen Eingang in das KPI-System.

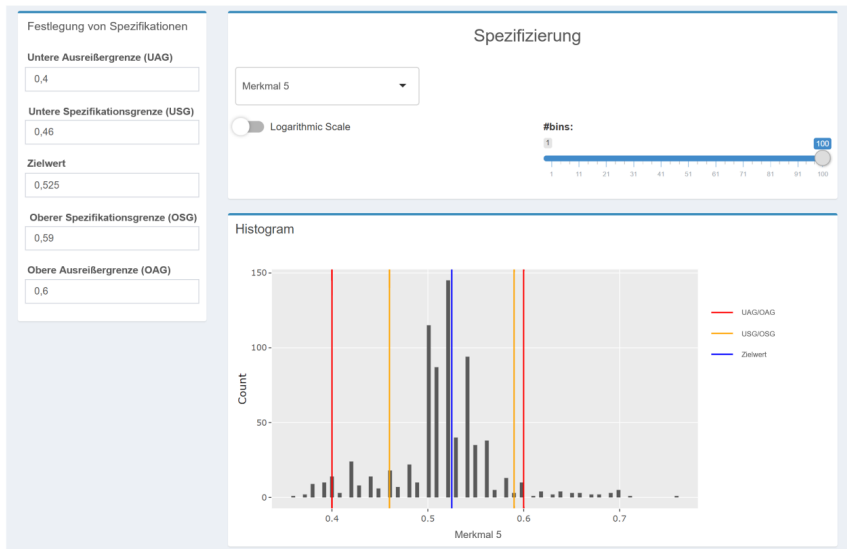


Abbildung 65: Prototypische Implementierung eines Histogramms zur Festlegung von Spezifikationen.

Das Ziel der **Modellierung** liegt in der Berechnung von Feature Importances, welche den relativen Einfluss von Eingangsgrößen auf eine ausgewählte Zielgröße repräsentieren. Die Berechnung erfolgt auf Basis von AutoML. Mithilfe von AutoML können Maschine Learning Methoden ohne umfangreiche Programmierkenntnisse von Experten flexibel angewendet werden (vgl. Abschnitt 4.5.1). Die technische Umsetzung von AutoML erfolgt mithilfe des Open Source Paketes *H2O.ai*, welches die in Unterkapitel 4.5 diskutierten Anforderungen abdeckt. Die Anwendung der Modellierung wird in Abbildung 66 verdeutlicht. Demnach kann der zu analysierende Datensatz mithilfe zweier Filterfunktionen („Projektbezeichnung“ und „Chargennummer“) selektiert werden. Im Folgenden sind die Eingangsgrößen, die Zielgröße und eine Experimentbezeichnung festzulegen. Mithilfe der Trainingszeit erfolgt eine Gewichtung der Modellgenauigkeit und Interpretierbarkeit. Das bedeutet, dass bei der Auswahl einer kurzen Trainingszeit auf simple Modelle, wie bspw. lineare Regressionen oder Entscheidungsbäume,

zurückgegriffen wird. Die Auswahl simpler Modelle geht oft mit einer hohen Interpretierbarkeit und geringer Modellgenauigkeit einher (vgl. MURDOCH ET AL. 2019, S. 2 und SCHNELL ET AL. 2019, S. 364). Eine Selektion unterschiedlicher Modelle auf Basis der Trainingszeit erfolgt innerhalb des Pakets von *H2O.ai*.

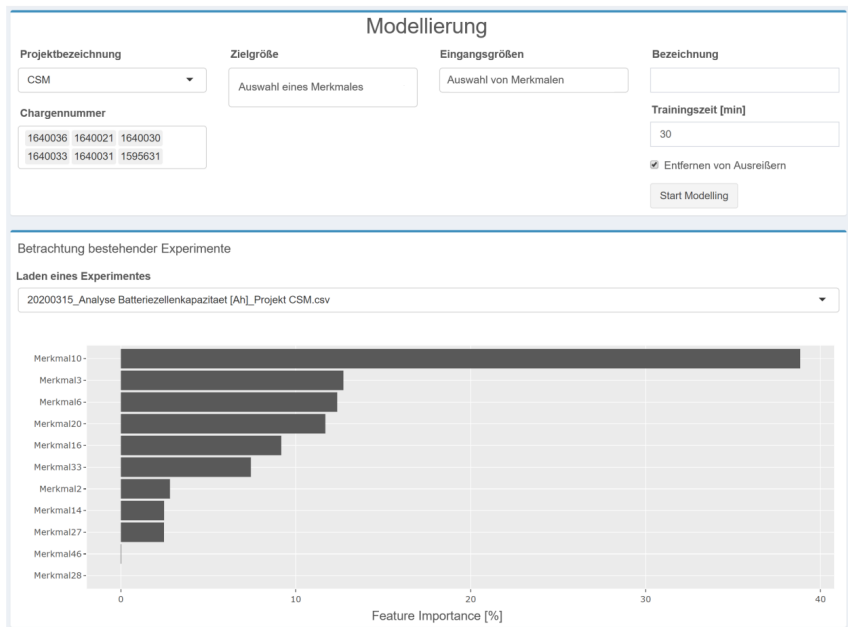


Abbildung 66: Prototypische Implementierung der Modellierung auf Basis von AutoML.

Nach erfolgreicher Modellierung werden die Ergebnisse in einem Dokument abgelegt. Auf diese Weise können auch vergangene Experimente jederzeit abgerufen werden, um bspw. als Referenz für weitere Analysen zu dienen (vgl. Auswahlfeld „Laden eines Experimentes“). Es lässt sich zusammenfassen, dass die beschriebenen Funktionen der Self-Service Data Analytics darauf ausgelegt sind, die Experten in den Prozess der Datenanalyse zu integrieren. Auf diese Weise kann der Experte sein eigenes Vorwissen bzw. die Ergebnisse des Bayesschen Netzwerkes nutzen, um die Datenanalyse zu optimieren und Ergebnisse zu plausibilisieren. Umgekehrt kann mithilfe der Datenanalyse das beschriebene Bayessche Netzwerk verifiziert werden.

Neben der Umsetzung der zentralen Lösungsbausteine findet sich in der prototypischen Implementierung auch eine **Produktionsübersicht** wieder. Diese stellt ein Dashboard dar, in welchem Informationen für unterschiedliche Anwender bereitgestellt werden. Mithilfe von Nutzerprofilen lassen sich die einzelnen Register personalisieren. So kann die **Produktionsüberwachung** auf Basis aktueller Produktionszahlen und Ausschüsse eine Ansicht für die Unternehmenssteuerung präsentieren. Eine detaillierte Darstellung der einzelnen Produktionsschritte kann Entwickler und Anlagebediener unterstützen. Darüber hinaus stellt die Produktionsübersicht eine Möglichkeit zur automatisierten Erstellung von **EoL-Protokollen** (End-of-Line) bereit und bietet eine Schnittstelle für den **Datenexport**.

Damit das implementierte experten- und datenbasierte Qualitätsmanagementsystem als dynamisches Entscheidungsunterstützungssystem verwendet werden kann, wird ein webbasierter Zugriff auf Basis eines **Servers** (Client-Server-Modell) bereitgestellt (vgl. THIENEN 2013, S. 5 ff.). Hierdurch lässt sich die prototypische Implementierung per Webbrowser mobil auf unterschiedlichen Endgeräten nutzen.

#### 4.6.3 Zusammenfassung und kritische Gegenüberstellung der Anforderungen

Um eine kontinuierliche Produkt- und Prozessoptimierung während eines vollständigen Produktionsanlaufes zu erzielen, wurden die drei zentralen Lösungsbausteine KPI-System, Bayessches Netzwerk und Self-Service Data Analytics im Rahmen der prototypischen Implementierung zu einem Gesamtsystem verknüpft. Eine Strukturierung erfolgt dabei anhand einer Daten-, Logik- und Visualisierungsebene.

Mithilfe der prototypischen Implementierung konnte ein Nachweis über die *Praxistauglichkeit des Gesamtkonzepts (A<sub>44</sub>)* erbracht werden. Aufgrund der hohen Anwendbarkeit des Bayesschen Netzwerkes und der Self-Service Data Analytics sind *Fertigungsebene, Fertigungslebene und Entwicklungspersonal (A<sub>17</sub>)* in der Lage, eine Datenanalyse oder Fehler-Ursachen-Analyse eigenständig durchzuführen und dadurch Iterationszeiten zu reduzieren. Die *Nachvollziehbarkeit des Gesamtkonzepts (A<sub>45</sub>)* wird durch einen systematischen Ablauf, eine einfache Durchführbarkeit und klare Gliederung der einzelnen Register erzielt. Aus Sicht der Experten bzw. Entscheidungsträger fördert dies die Akzeptanz und das Vertrauen in die verwendeten Methoden (CLEFF 2015, S. 13). Die Praxistauglichkeit wird insbesondere auch durch die Datenarchitektur unterstützt, welche eine Echtzeitanwendung der diskutierten Methoden ermöglicht. Des Weiteren wird auch die Anforderung an eine *Wissensdatenbank (A<sub>43</sub>)* erfüllt, da mithilfe des Produkt- und Prozessmodells Ursachen-Wirkzusammenhänge strukturiert und aktualisierbar abgelegt werden können. Ausgehend von einer kleinen Wissensbasis zu Beginn

eines Produktionsanlaufes bis hin zur Serienproduktion ist die *Skalierbarkeit* (**A<sub>18</sub>**) dieser Wissensdatenbank gegeben.



## 5 Exemplarische Anwendung

Im Folgenden werden die entwickelten zentralen Lösungsbausteine an einem Fallbeispiel verdeutlicht. Zusammen mit der zuvor beschriebenen prototypischen Implementierung soll dadurch eine Validierung des entwickelten Konzepts erfolgen.

Die exemplarische Anwendung des Qualitätsmanagementsystems erfolgte im *BMW Group Kompetenzzentrum für Batteriezellen*. Im Fallbeispiel wird die Prototypenproduktion prismatischer Lithium-Ionen-Batteriezellen betrachtet, welche einen Teil des Produktionsanlaufes bildet. In Unterkapitel 5.1 erfolgt zunächst eine Vorstellung des im Fallbeispiel diskutierten Prozesskettenabschnittes. Anhand eines hierbei festgestellten Fehlers wird nachfolgend die Anwendung des in der vorliegenden Arbeit entwickelten Qualitätsmanagementsystems verdeutlicht. Die Anwendung erfolgte in Anlehnung an das Konzept aus Abbildung 27 in den folgenden Schritten:

- Qualitätsprüfung auf Basis des KPI-Systems zur Identifizierung des Fehlers (Unterkapitel 5.2)
- Aufbau des Bayesschen Netzwerkes auf Basis einer FMEA (Unterkapitel 5.3), welche die Grundlage einer zielorientierten Fehler-Ursachen-Analyse bildet (Unterkapitel 5.4)
- Identifikation weiterer Ursachen-Wirkzusammenhänge auf Basis der Self-Service Data Analytics (Unterkapitel 5.5)

### 5.1 Vorstellung des betrachteten Prozesskettenabschnittes

Der im Fallbeispiel betrachtete Prozesskettenabschnitt lässt sich Abbildung 67 entnehmen. Demnach liegt der Fokus auf den Bereichen der Zellaassemblierung und Zellaktivierung. Die Bereiche zeichnen sich durch 14 konsekutive Schritte aus, beginnend mit einer Materialprüfung der Anoden- und Kathodenbahnen und endend mit der Formierung der Batteriezellen. Betrachtet wird dabei ein Zelltyp mit einheitlichem Elektrodenmaterial. Um einen Wassereintrag und eine Kontamination durch Partikel in den Zellmaterialien zu vermeiden, findet die Zellaassemblierung in einem Trockenraum mit Reinraumanforderungen statt (SIMON 2013, S. 251).

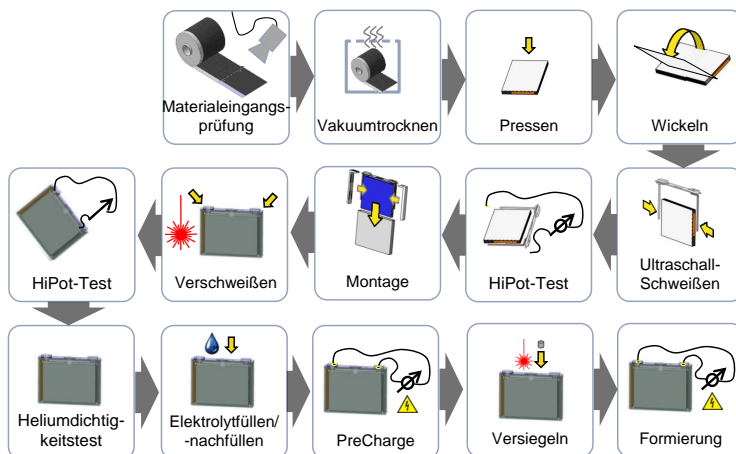


Abbildung 67: Darstellung des im Fallbeispiel betrachteten Prozesskettenabschnittes.

## 5.2 Qualitätsprüfung

Die Qualitätsprüfung, welche im Fallbeispiel diskutiert wird, erfolgte im Betrachtungsumfang von Chargen. Da die Chargen eine Mindestlosgröße von 25 Batteriezellen aufwiesen, konnte für die Bewertung auf die Prozessfähigkeitsindizes  $c_{pk}$  bzw.  $c_{pmk}$  zurückgegriffen werden. Qualitätsregelkarten stellten das wesentliche Instrument zur Überwachung des Prozessverlaufes dar. Diese stützen sich, wie Abschnitt 2.2.5 erläutert, auf Grenzen, aus denen sich wiederum Handlungsregeln ableiten ließen (LINß 2013, S. 306 ff.). Die Grenzen und die dazugehörigen Handlungsregeln wurden im Vorfeld mit Experten für die Anwendung einer Prototypenproduktion wie folgt definiert:

- Untere Warngrenze – der Prozess ist mit erhöhter Aufmerksamkeit zu beobachten.
- Untere Eingriffsgrenze – es wird eine Untersuchung des Prozesses empfohlen.
- Untere Mindestgrenze – der Prozess weist ungenügende Qualität auf und ist zu unterbrechen.

Alternativ wäre auch eine Berechnung dieser Grenzen möglich (vgl. LINß 2013, S. 309).

Abbildung 68 verdeutlicht die im Fallbeispiel durchgeführte Qualitätsprüfung. Zu erkennen ist eine fehlerhafte Charge (Auftragsnummer 165011), die eine Qualitätsabweichung in der Kapazität aufwies. Um auf die Ursachen des identifizierten Fehlerbildes zu schließen, fand eine Fehler-Ursachen-Analyse auf Basis des Bayesschen Netzwerkes statt. Der Aufbau und die

Anwendung des Bayessche Netzwerkes werden in den nachfolgenden Abschnitten verdeutlicht.




Abbildung 68: Qualitätsregelkarte als Teil des KPI-Systems zur Überwachung der Kapazität von produzierten Chargen.

### 5.3 Aufbau des Bayesschen Netzwerkes

Das Bayessche Netzwerk soll angewendet werden, um die Ursachen für die Kapazitätsabweichung zu identifizieren. In dem vorliegenden Abschnitt wird zunächst der Aufbau des Bayesschen Netzwerkes für den betrachteten Prozesskettenabschnitt diskutiert. Die anschließende Anwendung des Bayesschen Netzwerkes wird in Unterkapitel 5.4 beschrieben.

Die FMEA bildete die Grundlage für den Aufbau des Bayesschen Netzwerkes. Die Erstellung der FMEA erfolgte basierend auf den VDA Richtlinien (vgl. VDA Band 4) mithilfe der Software *APIS IQ-FMEA*. Der Aufbau des Fehlernetzwerkes wurde im Rahmen mehrerer moderierter Workshops mit Hilfe eines Expertenteams unterschiedlicher Fachbereiche durchgeführt.

Das aufgestellte Fehlernetzwerk ist Abbildung 69 zu entnehmen. Fehlerknoten, wie bspw. „Elektrolytmenge außerhalb der Toleranz“ sind dabei durch farblich markierten Kästchen gekennzeichnet. Die Verbindungslinien zwischen einzelnen Fehlerknoten repräsentieren Ursachen-Wirkzusammenhänge. Das Fehlernetzwerk weist insgesamt 400 Fehlerknoten mit einer prozessübergreifenden Wirkung auf. Dies verdeutlichte die in der Batteriezelleproduktion vorliegende Komplexität. Darüber hinaus wurde beim Aufbau des Fehlernetzwerkes ersichtlich, dass die einzelnen Fehlerknoten bis zu 32 Elternknoten aufwiesen. Dies unterstrich die Notwendigkeit von Aggregierungsknoten, um bei der Durchführung von Inferenzen anwendergerechte Berechnungszeiten zu erzielen. (KIRCHHOF ET AL. 2020)




Abbildung 69: Initiales Fehlernetzwerk der Zellassemblierung und Zellaktivierung (aus KIRCHHOF ET AL. 2020).

Das Fehlernetzwerk zeichnete sich durch eine Vielzahl von inkonsistenten Fehlerknoten aus, die sich über den gesamten Fertigungsprozess verteilten (vgl. Abbildung 70). So wiesen 121 der insgesamt 423 Fehlerknoten widersprüchliche Expertenbewertungen in den Wahrscheinlichkeiten auf. Diese hohe Anzahl an Inkonsistenzen lässt sich darauf zurückführen, dass im

Fallbeispiel der Aufbau der FMEA, entgegen der in Abbildung 48 empfohlenen Vorgehensweise nicht prozessweise von dem beschriebenen Empfehlungsalgorithmus begleitet wurde.



Abbildung 70: Initiales Fehlernetzwerk mit hervorgehobenen inkonsistenten Fehlerknoten.

Im Weiteren wurde deutlich, dass es den Experten schwerfiel, Fehlerknoten mit mehreren Elternknoten zu bewerten (vgl. Abbildung 71). Dies korreliert mit den Untersuchungen von HALFORD ET AL., wonach Menschen kognitiv nicht in der Lage sind, eine Vielzahl von Variablen gleichzeitig zu verarbeiten (HALFORD ET AL. 2005).




Abbildung 71: Darstellung der inkonsistenten Fehlerknoten bezogen auf die Anzahl an Elternknoten.

Obwohl die FMEA beim Aufbau nicht durch einen Empfehlungsalgorithmus begleitet wurde, wurde der Empfehlungsalgorithmus genutzt, um das inkonsistente Fehlernetzwerk nachträglich zu korrigieren. Aufgrund der hohen Anzahl an Inkonsistenzen war eine Mehrfachanwendung des Empfehlungsalgorithmus notwendig.

Ein Vergleich zwischen dem initialen, inkonsistenten Fehlernetzwerk und dem durch den Empfehlungsalgorithmus korrigierten Fehlernetzwerk soll mithilfe der Abbildung 72 a) und b) erzielt werden. In Abbildung 72 a) wird auf eine Darstellung der relativen Häufigkeit zurückgegriffen, da eine diskrete Änderung der Kennzahl der Auftretenswahrscheinlichkeit  $W(f_i)$  vorlag.




Abbildung 72: a) Relative Änderung der Kennzahlen der Auftretenswahrscheinlichkeiten; b) Relative Änderung der Fehlerfolgswahrscheinlichkeiten  $p_{i,j}$ .

Abbildung 72 b) zeigt die relative Änderung der Fehlerfolgswahrscheinlichkeit  $p_{i,j}$  mithilfe einer Dichtefunktion, da hierbei eine kontinuierliche Variable betrachtet wird. In beiden Abbildungen

wird lediglich auf 213 der insgesamt 423 Fehlerknoten Bezug genommen, da diese Elternknoten besitzen und somit eine Inkonsistenz hervorrufen könnten. Es lässt sich ableiten, dass eine Vielzahl dieser 213 Fehlerknoten nach Verwendung des Empfehlungsalgorithmus unverändert blieb. Die Auftretenswahrscheinlichkeit  $W(f_i)$  wurde in den meisten Fällen erhöht und die Fehlerfolgswahrscheinlichkeit  $p_{i,j}$  verringert. Dies korreliert mit dem in Abschnitt 4.4.5 diskutierten Ansatz zur Reduzierung von Inkonsistenzen. Das korrigierte Bayessche Netzwerk bildete die Ausgangslage für die Fehler-Ursachen-Analyse und wird im nachfolgenden Abschnitt diskutiert.

## 5.4 Fehler-Ursachen-Analyse

Das konsistente Bayessche Netzwerk wurde verwendet, um die Ursache für die fehlerhafte Charge aus Abbildung 68 zu identifizieren. Abbildung 73 stellt die initiale Fehler-Ursachen-Analyse für die Kapazitätsabweichung auf Basis der prototypischen Implementierung dar.

Fehler-Ursachen-Analyse

Batteriezellen-ID (optional):

Diese Fehler sind aufgetreten:

Formierung - Kapazität ist ausserhalb des angegebenen Toleranzbereichs

Diese Fehler sind nicht aufgetreten:

No failures

Priorisierung von Fehlerursachen:

Ursachen- wahrscheinl.	Ebene	Ursache	Prozesskettenelement der Ursache
35.25%	1	PreCharge - Ladekapazität ist ausserhalb des angegebenen Toleranzbereichs	<div style="display: flex; justify-content: space-around;"> <span>✓</span> <span>✗</span> </div> PreCharge - Kapazität
18.41%	1	Formierung - Ladungsmenge ist ausserhalb des angegebenen Toleranzbereichs	<div style="display: flex; justify-content: space-around;"> <span>✓</span> <span>✗</span> </div> Formierung - Ladungsmenge
18.29%	1	Formierung - Dauer ist ausserhalb des angegebenen Toleranzbereichs	<div style="display: flex; justify-content: space-around;"> <span>✓</span> <span>✗</span> </div> Formierung - Dauer
9.62%	1	Befuellen - Dosiervolumen ist ausserhalb des angegebenen Toleranzbereichs	<div style="display: flex; justify-content: space-around;"> <span>✓</span> <span>✗</span> </div> Befuellen - Fuelkammer Dosiervolumen
9.07%	1	Formierung - Spannung ist ausserhalb des angegebenen Toleranzbereichs	<div style="display: flex; justify-content: space-around;"> <span>✓</span> <span>✗</span> </div> Formierung - Maximalspannung

Previous
1
2 3 4 5 ... 72 Next

Abbildung 73: Initiale Fehler-Ursachen-Analyse für das Fehlerbild „Formierung – Kapazität ist außerhalb des angegebenen Toleranzbereiches“.

Hierdurch wurden den Experten potenzielle Fehlerursachen in priorisierter Auflistung bereitgestellt. Es erfolgte eine Plausibilisierung, in welcher sichtbar wurde, dass das Hinzufügen von Evidenzen notwendig war, um die initiale Fehlerursache weiter einzuzugrenzen (vgl. Abbildung 74). Evidenzen wurden auf Basis objektiver und subjektiver Prüfmethode ergänzt. So wurde mithilfe des KPI-Systems bspw. identifiziert, dass auch die bei der Formierung eingebrachte Ladungsmenge ungenügend war. Mithilfe einer Sichtprüfung erfolgte die Überprüfung der Spannungskontakte in der Formierung. Die interaktive Benutzeroberfläche der prototypischen Implementierung unterstützte die flexible Auswahl der Evidenzen und ermöglichte eine responsive Neuberechnung der Fehlerursachen. Auf diese Weise ließ sich herausfinden, dass eine unbekannte Ursache für die Kapazitätsabweichung der Charge verantwortlich war. Die unbekannte Ursache ist als quantifizierte Wissenslücke der Experten im Prozessschritt der Formierung zu betrachten. Sie beschreibt, dass, unter der Annahme der identifizierten Evidenzen, zu 84 % eine weitere Ursache für die fehlerhafte Kapazität und Ladungsmenge in der Formierung vorlag.

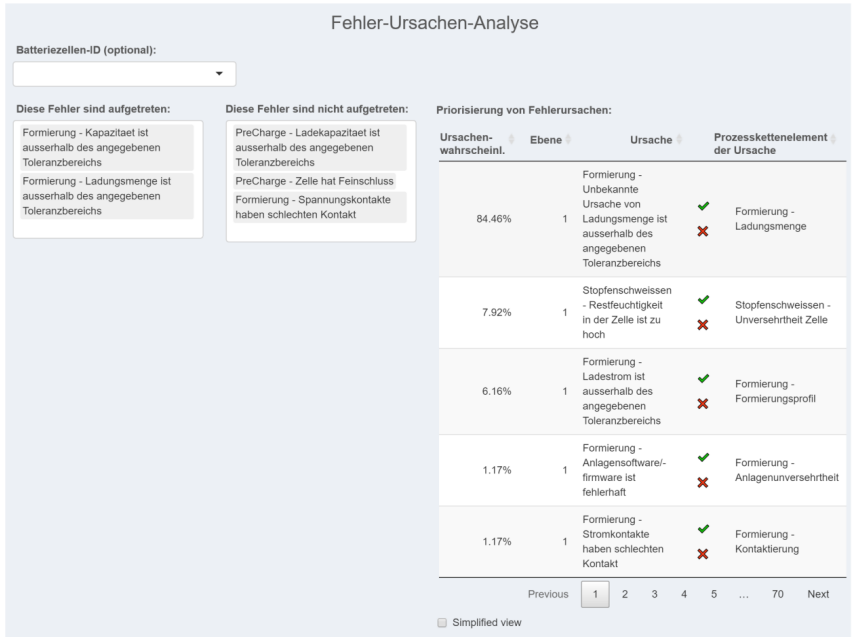


Abbildung 74: Drilldown der Fehler-Ursachen-Analyse auf Basis weiterer Evidenzen.



Die im Rahmen der FMEA identifizierten Ursachen-Wirkzusammenhänge waren demnach nicht ausreichend, um das Bayessche Netzwerk für eine zielorientierte Fehler-Ursachen-Analyse zu nutzen. Eine Identifizierung weiterer Ursachen-Wirkzusammenhänge sollte mithilfe der Datenanalyse auf Basis der Self-Service Data Analytics erzielt werden.

## 5.5 Datenanalyse

Für die Datenanalyse lag eine umfassende Datenbasis vor, welche Materialinformationen, Maschinen- und Prozessparameter sowie Information zur technischen Gebäudeausrüstung enthielt. Für die Analyse der fehlerhaften Charge standen Daten mit insgesamt 239 Merkmalen zur Verfügung. Wie in Unterkapitel 4.5 beschrieben und in Abschnitt 4.6.2 verdeutlicht, erfolgte die Datenanalyse anhand der spezifizierten Phasen der Self-Service Data Analytics. Die Ergebnisse der Modellierung, welche auf Basis von AutoML berechnet wurden, sind Abbildung 75 zu entnehmen und werden im Folgenden diskutiert.

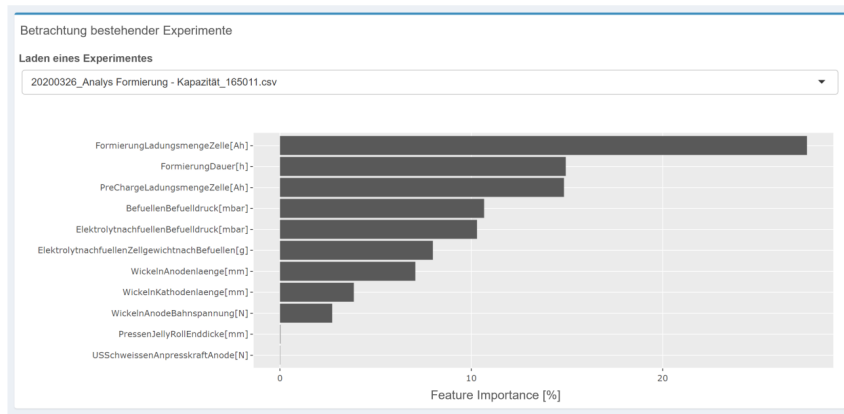


Abbildung 75: Ergebnisse des AutoML für die Zielgröße Kapazität der Produktionscharge 165011.

Zu erkennen sind dabei die Feature Importances, welche den relativen Einfluss von Eingangsgrößen auf die ausgewählte Zielgröße beschreiben (vgl. Abschnitt 4.5.1). Die Zielgröße wird durch die Kapazität dargestellt. Da Ladungsmenge und Dauer der Formierung einen trivialen Einfluss auf die Kapazität aufweisen, wurden diese Zusammenhänge von den Experten nicht weiter berücksichtigt. Einen weiteren Einfluss auf die Kapazität stellten gemäß Abbildung 75 die Drücke der Prozessschritte Befüllen und Elektrolytnachfüllen dar. Durch einen Vergleich

mit Experimenten vergangener Chargen (vgl. Abbildung 75, Feld „Laden eines Experimentes“) konnte die Signifikanz dieser Zusammenhänge bestätigt werden. Es folgte eine Korrelationsanalyse, in welcher insbesondere ein Zusammenhang zwischen dem Druck des Befüllprozesses und der Kapazität aufgezeigt werden konnte (vgl. Scatterplot der Paramater „Befüllen Befülldruck [mbar]“ und „Formierung Kapazität [Ah]“ in Abbildung 76).



Abbildung 76: Korrelationsanalyse ausgewählter Merkmale der Produktionscharge 165011.

Eine mögliche Erklärung dieses Zusammenhanges ist, dass der Befülldruck die Benetzung des Elektrolyten mit dem Elektrodenmaterial beeinflusst (vgl. GÜNTER ET AL. 2020). Elektrodenmaterial, welches unzureichend benetzt ist, wird elektrochemisch als inaktiv betrachtet und kann zu einer Kapazitätsreduzierung führen. Dies stellt einen qualitätsrelevanten Ursachen-Wirkzusammenhang dar, welcher in die FMEA aufgenommen wurde und somit für zukünftige Fehler-Ursachen-Analysen vorliegt.

Nachfolgend wird die Ausschussreduzierung errechnet, die mithilfe der Fehler-Ursachen-Analyse erzielt wurde. Analog zu Tabelle 8-2 wird die Annahme getroffen, dass die Kapazität einer Normalverteilung unterliegt und der Mittelwert  $\mu$  dem Sollwert entspricht (vgl. LINß 2013, S. 626 ff.). Gemäß Abbildung 68 lässt sich der gewichtete Mittelwert der Prozessfähigkeit der ersten neun aufgezeichneten Chargen berechnen als  $c_{pk_{1-9}} = 1,1$ . Der fehlerhafte Auftrag (Chargennummer 165011) wies einen Prozessfähigkeitsindex von  $c_{pk_{10}} = 0,47$  auf. Nach COSKUN ET AL. lässt sich die Fehlerhäufigkeit als DPMO (Fehler pro Million Möglichkeiten) auf Basis der Prozessfähigkeit wie folgt errechnen (COSKUN ET AL. 2019, S. 3):

$$DPMO = 10^6 \times 2 \times (1 - \Phi(3 \times c_{pk})) \quad (5.1)$$

Dabei repräsentiert  $\Phi$  die Verteilungsfunktion der Normalverteilung unter den Bedingungen  $\mu = 0$  und  $\sigma = 1$ . Hieraus ergibt sich die Fehlerhäufigkeit für die ersten neun aufgezeichneten Aufträge  $DPMO_{1-9}$  sowie des fehlerhaften Auftrages  $DPMO_{10}$ :

$$DPMO_{1-9} = 1000000 \times 2 \times (1 - \Phi(3 \times 1,10)) = 996,85 \quad (5.2)$$

$$DPMO_{10} = 1000000 \times 2 \times (1 - \Phi(3 \times 0,47)) = 158539,70 \quad (5.3)$$

Sollten die oben postulierten Annahmen nicht eingehalten und dem Mittelwert ein Freiraum von bspw.  $\mu = \pm 1,5 \sigma$  gewährt werden, so vergrößert sich die Fehlerhäufigkeit (vgl. LINß 2013, S. 624-625).

Es lässt sich zusammenfassen, dass mithilfe des diskutierten Fallbeispiels eine Validierung des entwickelten Qualitätsmanagementsystems erbracht werden konnte. In Anlehnung an das Konzeptbild aus Abbildung 27 erfolgte eine Anwendung der zentralen Lösungsbausteine, mit-

hilfe derer eine Qualitätsprüfung, eine Fehler-Ursachen-Analyse sowie die Identifikation weiterer Ursachen-Wirkzusammenhänge erzielt werden konnte. Die Methoden haben eine zeiteffiziente Identifizierung der Fehlerursache ermöglicht, welche einen theoretischen Ausschuss von 15,85% zur Folge gehabt hätte.

## 6 Zusammenfassung und Ausblick

Das letzte Kapitel der vorliegenden Arbeit dient einer Zusammenfassung der relevanten Forschungsergebnisse (Unterkapitel 6.1). Mithilfe der kritischen Würdigung (Unterkapitel 6.2) erfolgt zudem ein Aufzeigen des Stellenwerts gegenüber dem Stand der Forschung und eine Diskussion der Grenzen der entwickelten Methoden. Der abschließende Ausblick (Unterkapitel 6.3) stellt Potenziale zur Weiterentwicklung des Qualitätsmanagementsystems dar.

### 6.1 Zusammenfassung

Die fortschreitende Verknappung von Ressourcen, wachsendes Umweltbewusstsein und gesetzliche Regelungen führen zu einem weltweiten Anstieg in der Anzahl elektrifizierter Fahrzeuge (GUTZMER & TODSEN 2019, S. 7). Batteriezellen tragen einen wesentlichen Teil zu dieser Entwicklung bei, da sie aus technischer Sicht und aus Kostenperspektive die elektrischen Fahrzeuge maßgeblich beeinflussen. Eine der großen Herausforderungen stellt allerdings der Herstellungsprozess von Batteriezellen dar, da dieser durch einen signifikant hohen Ausschuss von 5–12 % charakterisiert ist (BRODD & HELOU 2013, S. 298). Die Ausschussreduzierung in der Batteriezellenproduktion repräsentiert einen wesentlichen Hebel zur Senkung der Kosten elektrischer Fahrzeuge und produktionsbedingter CO<sub>2</sub>-Emissionen. Abgeleitet aus der dargelegten Motivation bestand das Ziel dieser Forschungsarbeit in der Entwicklung eines Qualitätsmanagementsystems, welches auf Basis geeigneter Methoden der Qualitätsprüfung und der Fehler-Ursachen-Analyse eine Ausschussreduzierung in der Produktion von Batteriezellen bewirkt.

Kapitel 1 beschreibt einführend die Herausforderungen einer Batteriezellenproduktion. Diese lassen sich auf Komplexitätsmerkmale zurückführen, wie bspw. die unterschiedlichen Prozessarten, den hohen Innovationsgrad, die Anzahl der Prozessschritte und Prozesskettenelemente sowie das Vorliegen von Ursachen-Wirkzusammenhängen. Hieraus leitete sich die Zielsetzung der Arbeit ab, welche in der Entwicklung eines Qualitätsmanagementsystems lag, das insbesondere für komplexe Prozessketten ausgelegt ist und produktionsanlaufbegleitend bis hin zum Serienbetrieb verwendet werden kann.

In Kapitel 2 erfolgte eine Einführung in die theoretischen Grundlagen. Es wurden die im Kontext dieser Arbeit stehenden Themenfelder Qualität, Komplexität, Kausalität und Prozesse diskutiert. Es folgte eine Vorstellung etablierter Qualitätsmanagementmethoden, die für das

Verständnis des entwickelten Konzeptes und dessen zentraler Lösungsbausteine relevant waren. Dabei wurden Ansätze der Datenanalyse und Statistik, wie Prozessfähigkeitsuntersuchungen und Bayessche Netzwerke, diskutiert.

Kapitel 3 beschreibt den Stand der Forschung im Kontext des Qualitätsmanagements. Es erfolgte zunächst die Klassifizierung und Beschreibung von Bewertungskriterien, welche die Grundlage einer systematischen Analyse darstellen. Aus dem Stand der Forschung ließ sich ableiten, dass keine der herangezogenen Arbeiten auf das Potenzial zugreift, expertenbasierte und datenbasierte Ansätze synergetisch zu nutzen, um Ursachen-Wirkzusammenhänge zu identifizieren. Ebenfalls wurde die Notwendigkeit erkannt, etablierte Prozesse der Datenanalyse konzeptionell weiterzuentwickeln, um Ergebnisse für Nutzer zugänglich zu machen. Unter dem Aspekt eines Produktionsanlaufes stellte die Entwicklung eines ganzheitlichen Qualitätsmanagementkonzepts, in welchem ein systematischer Ansatz zur Prozessführung, die Berechnung von KPIs sowie eine Fehler-Ursachen-Analyse integriert sind, eine weitere Forschungslücke dar.

Abgeleitet aus den Forschungslücken erfolgte in Kapitel 4 die Entwicklung eines Qualitätsmanagementsystems, welches sich an die Grundidee eines Qualitätsregelkreises anlehnt. Das Qualitätsmanagementsystem besteht aus drei zentralen Lösungsbausteinen, welche den Schwerpunkt der Forschungsarbeit bilden. Die Identifizierung von Fehlern und Produktionsausschüssen, als Voraussetzung einer Prozessführung, stellt den ersten Lösungsbaustein dar und wurde mithilfe eines KPI-Systems realisiert. Um isolierte Fehler an einzelnen Prozesskettenelementen oder ein Zusammenwirken von mehreren Einflussfaktoren zu berücksichtigen, wurden geeignete univariate Methoden identifiziert und ein multivariates Kennzahlensystem erarbeitet. Das Zusammenführen dieser beiden Ansätze in eine Qualitätsregelkarte stellt ein weiteres Hauptmerkmal des erarbeiteten KPI-Systems dar. Den zweiten Lösungsbaustein des Qualitätsmanagementsystems bildet ein FMEA-basiertes Bayessches Netzwerk. Es repräsentiert eine Methode zur Fehler-Ursachen-Analyse und ermöglicht die Durchführung von Inferenzen, auf deren Basis Qualitätsmaßnahmen priorisiert werden können. Um den Anforderungen in der komplexen Prozesskette einer Batteriezellenproduktion gerecht zu werden, lag der Fokus auf der Weiterentwicklung der Bayesschen Netzwerke. Der dritte Lösungsbaustein des Qualitätsmanagementsystems zielte auf die Erarbeitung eines durch Experten gestützten Konzepts zur Datenanalyse ab und wird als Self-Service Data Analytics bezeichnet. Es wurde deutlich, dass insbesondere Visual Analytics und AutoML zweckmäßige Lösungen darstellen, um den Prozess der Datenanalyse zu fördern. Im letzten Unterkapitel wurde die prototypische Implementierung des Qualitätsmanagementsystems diskutiert. Hierdurch

konnte der Nachweis erbracht werden, dass sich die drei Lösungsbausteine zu einem Gesamtsystem verknüpfen lassen und eine synergetische Anwendung der experten- und datenbasierten Ansätze möglich ist.

Ausgehend von der prototypischen Implementierung erfolgt in 5 eine exemplarische Anwendung des entwickelten Qualitätsmanagementsystems und seiner Lösungsbausteine anhand eines Fallbeispiels.

## 6.2 Kritische Würdigung

Wenngleich die Idee eines Qualitätsregelkreises nicht neu ist, repräsentiert das entwickelte Qualitätsmanagementsystem eine ganzheitliche Methode, in welchem sowohl expertenbasierte als auch datenbasierte Ansätze eingebunden sind. Während die in Kapitel 3 diskutierten Forschungsarbeiten experten- und datenbasierten Methoden unabhängig voneinander betrachten, zeichnet sich das entwickelte Konzept durch eine synergetische Verknüpfung dieser beiden Domänen aus. Auf diese Weise lässt sich der Übergang vom rein expertenbasierten Wissen, welches zu Beginn einer Prototypenproduktion vorliegt, bis hin zur Serienproduktion gestalten, da mithilfe der Self-Service Data Analytics Ursachen-Wirkzusammenhänge fundiert ergänzt werden können. Durch die Weiterentwicklung statistischer Methoden, wie bspw. des Bayesschen Netzwerkes oder der Prozessfähigkeitsuntersuchung, wird insbesondere eine Eignung für komplexe Prozessketten gewährleistet.

Eine kritische Betrachtung der Ergebnisse zeigt allerdings auch Grenzen des Qualitätsmanagementsystems auf, welche anhand der drei zentralen Lösungsbausteine KPI-System, FMEA-basiertes Bayessches Netzwerk und Self-Service Data Analytics nachfolgend diskutiert werden.

### KPI-System

In Bezug auf das KPI-System ist hervorzuheben, dass die Berechnung von Prozessfähigkeitsindizes eine Mindestmenge von 25 Stichproben erfordert. Aufgrund dessen lässt sich das entwickelte KPI-System insbesondere in einer Prototypenproduktion nicht uneingeschränkt verwenden, sodass auch auf subjektive Prüfmethoden zurückzugreifen ist. Auch das multivariate Kennzahlensystem unterliegt Einschränkungen, da es auf Korrelationen der Merkmale von Prozesskettenelementen angewiesen ist. Eine Anwendbarkeit dieser Methode liegt somit nur vor, sofern die der Produktion zugrundeliegende Datenbasis eine ausreichend hohe Quantität und Qualität aufweist, um alle relevanten Korrelationen zu identifizieren.

### **FMEA-basiertes Bayessches Netzwerk**

Die exemplarische Anwendung verdeutlicht, dass Inkonsistenzen eine wesentliche Limitierung Bayesscher Netzwerke darstellen können. Da in dem diskutierten Fallbeispiel auf eine bereits bestehende FMEA zurückgegriffen wurde, war eine Mehrfachanwendung des Empfehlungsalgorithmus notwendig, um der hohen Anzahl von Inkonsistenzen entgegenzuwirken. Darüber hinaus zeigte sich, dass teilweise große Änderungen in den Anpassungen der Wahrscheinlichkeiten vorgenommen werden mussten, um eine gesamthafte Konsistenz des Fehlernetzwerkes zu erzielen. Es gilt demnach zu überprüfen, ob eine Reduzierung von Inkonsistenzen tatsächlich erreicht wird, wenn der Empfehlungsalgorithmus bereits während und nicht erst nach Aufbau einer FMEA verwendet wird. Zuletzt erfolgte der Aufbau des Bayesschen Netzwerkes und die Konsistenzprüfung lediglich an einem Prozesskettenabschnitt der Batteriezielherfertigung. Es ist deshalb zu untersuchen, welche Auswirkungen sich auf das Bayessche Netzwerk und die Konsistenz des Fehlernetzwerkes ergeben, wenn die Prozesskette um die Elemente der Elektrodenherstellung ergänzt werden.

### **Self-Service Data Analytics**

Der Schwerpunkt der Self-Service Data Analytics liegt in der konzeptionellen Auslegung eines durch Experten getriebenen Prozesses der Datenanalyse. Hierbei findet kein Anspruch auf Vollständigkeit bzgl. Datensicherungs-, Datenvorverarbeitungs- oder Datenanalysemethoden statt. Im Detail wurden jedoch das AutoML und die Interpretationsmodelle auf Basis von Feature Importances diskutiert. Die hier vorgestellte Methode repräsentiert einen Ansatz zur globalen Interpretation eines Datensatzes. Nach DU ET AL. können insbesondere lokale Interpretationsmöglichkeiten eingesetzt werden, um einzelne Datenpunkte (hier: Batteriezellen) zu interpretieren (vgl. DU ET AL. 2020 und ELSHAWI ET AL. 2019). Lokale Interpretationsmöglichkeiten wurden im Rahmen dieser Forschungsarbeit nicht betrachtet. Sie stellen jedoch eine potenzielle Möglichkeit dar, die Interpretation der Modelle für Experten weiter zu fördern.

## **6.3 Ausblick**

Trotz der diskutierten Grenzen konnte der Nachweis einer erfolgreichen Implementierung und Validierung des Qualitätsmanagementsystems erbracht werden. Nachfolgend werden Weiterentwicklungsmöglichkeiten des Qualitätsmanagementsystems diskutiert. Es erfolgt dabei erneut eine Betrachtung anhand der drei Lösungsbausteine KPI-System, FMEA-basiertes Bayessches Netzwerk und Self-Service Data Analytics.



## KPI-System

Das erarbeitete multivariate Kennzahlensystem setzt die Kenntnis der Korrelationen zwischen Prozesskettenelementen voraus und eignet sich für einen fortgeschrittenen Produktionsanlauf einer Batteriezellenfertigung, in welcher eine hohe Datenqualität vorliegt. Um bereits in einer Prototypenproduktion auf die genannten Vorteile des multivariaten Kennzahlensystems zurückzugreifen, wäre es denkbar, die Korrelationskoeffizienten bereits zu Beginn einer Prototypenproduktion durch Experten zu bewerten. Im Verlauf des Produktionsanlaufes wäre dann eine sukzessive und fundierte Überprüfung sowie Erweiterung der Korrelationskoeffizienten auf Basis der Self-Service Data Analytics möglich. Die Korrelationen könnten, wie in Abbildung 77 verdeutlicht, in einer Design Structure Matrix abgelegt werden. Diese baut auf der Eigenschaft identischer Zeilen- und Spaltenbeschriftungen auf, in welchen Beziehungen (Korrelationen) eindeutig aufgezeigt werden können (BROWNING 2001, S. 292). Der Vorteil einer Design Structure Matrix liegt in der simplen und flexiblen Ablage von Koeffizienten, was eine Integration in das diskutierte Produkt- und Prozessmodell fördert (vgl. Abbildung 57).




Abbildung 77: Design Structure Matrix zur Sicherung experten- und datenbasierter Korrelationen.

## FMEA-basiertes Bayessches Netzwerk

In der Arbeit wurde das Bayessche Netzwerk auf Basis einer FMEA aufgebaut. Die von Experten bewerteten Ursachen-Wirkzusammenhänge wurden zudem mithilfe der Self-Service Data Analytics verifiziert und erweitert. Nach Li & Shi können Bayessche Netzwerke potenziell auch allein auf Basis von Daten erstellt werden (Li & Shi 2007). Der Aufbau erfolgt dabei mithilfe von Algorithmen, wobei in einem ersten Schritt der gerichtete azyklische Graph erstellt wird und darauffolgend die Wahrscheinlichkeitstabellen errechnet werden (Li & Shi 2007,

S. 683). Ein solcher Ansatz lässt sich allerdings nur unter der Prämisse einer hohen Datenqualität anwenden und würde, gemäß Abbildung 78, an das in dieser Forschungsarbeit entwickelte Konzept anschließen.

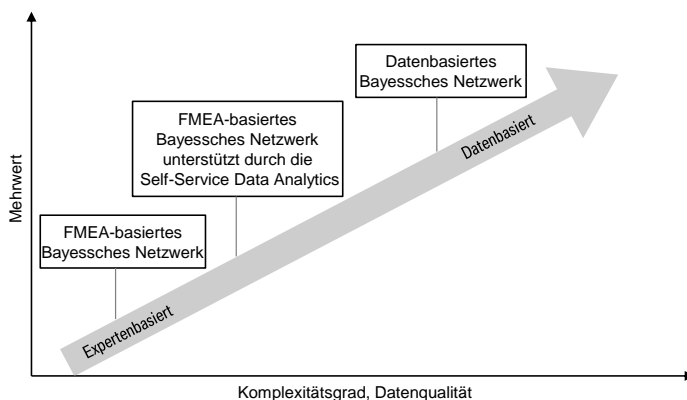


Abbildung 78: Einordnungen verschiedener Ansätze zum Aufbau Bayesscher Netzwerke.

Im Vergleich zur Self-Service Data Analytics liegt der Vorteil datenbasierter Bayesscher Netzwerke neben der Integration einer Fehler-Ursachen-Analyse insbesondere in einer hohen Modellinterpretation. Anstelle einer prozessübergreifenden Betrachtung von Eingangs- und Ausgangsrelationen auf Basis der diskutierten Feature Importances ermöglichen Bayessche Netzwerke die Betrachtung einzelner Fehlerknoten. An jedem Fehlerknoten wären demnach datenbasiert die Eingangs- und Ausgangsrelationen sowie prozessübergreifende Ursachen-Wirkzusammenhänge ersichtlich.

### Self-Service Data Analytics

Wie in Abschnitt 2.2.9, Abbildung 22 dargestellt, lässt sich die Datenanalyse in deskriptive, diagnostische, prädiktive und präskriptive Verfahren unterteilen. Die in dieser Arbeit entwickelten Ansätze zur Identifizierung von Ursachen-Wirkzusammenhängen lassen sich der deskriptiven Analyse zuordnen (vgl. WIRAEUS ET AL. 2019, S. 171). Die Fehler-Ursachen-Analyse bildet insbesondere durch die Möglichkeit der Fehlereingrenzung (auch als Drilldown bezeichnet) ein diagnostisches Verfahren (vgl. WIRAEUS ET AL. 2019, S. 172). Aufbauend auf dem Prozessmodell der Self-Service Data Analytics wäre im Weiteren zu untersuchen, ob auch

prädiktive Methoden der Datenanalyse implementiert werden könnten, um Prognosen von Ereignissen zu ermöglichen.

Die Self-Service Data Analytics ist für eine einkriterielle Analyse ausgelegt. Dies bedeutet, dass in der Modellierung und Modellinterpretation lediglich eine einzige Zielgröße betrachtet wird. Die Batteriezellenproduktion weist allerdings Anwendungsfälle auf, in denen mehrere Zielgrößen gleichzeitig berücksichtigt werden müssen. So beeinflusst bspw. die Elektrodenlänge nicht nur das Gewicht und die Kapazität einer Batteriezelle, sondern führt bei einer Veränderung insbesondere dazu, dass die beiden genannten Zielgrößen Gewicht und Kapazität sich in gegensätzliche Richtungen bewegen. Aufgrund der Vielzahl von Prozesskettenelementen und Zielgrößen bedarf es somit eines geeigneten multikriteriellen Ansatzes, um eine zielgerechte Optimierung zu realisieren (KORNAS ET AL. 2020, S. 3). In der Arbeit von KORNAS ET AL. wird gezeigt, dass auf Basis von Wünschbarkeitsfunktionen multikriterielle Optimierungen im Anwendungsbeispiel einer Batteriezellenproduktion umgesetzt werden können (KORNAS ET AL. 2020, S. 5-6). Wünschbarkeitsfunktionen erfordern die Einbringung von Expertenwissen und können mithilfe von Visual Analytics unterstützt werden (KORNAS ET AL. 2020, S. 3-4). Dies würde eine Integration der Wünschbarkeitsfunktionen in das Self-Service Data Analytics Modul begünstigen. Darüber hinaus wurde in der Arbeit von JESSENBERGER gezeigt, dass sich Wünschbarkeitsfunktionen ebenfalls für die Berechnung von Prozessfähigkeitsindizes verwenden lassen (JESSENBERGER & WEIHS 2005; JESSENBERGER 1999). Auf diese Weise wäre auch eine Integration in das gesamthafte Qualitätsmanagementsystem möglich.

## 7 Literaturverzeichnis

ABELE & D'ONOFRIO 2020

Abele, D.; D'Onofrio, S.: Artificial Intelligence – The Big Picture. In: Portmann, E. et al. (Hrsg.): Cognitive Computing. Wiesbaden: Springer Fachmedien Wiesbaden 2020. ISBN: 978-3-658-27940-0.

ABRAHAM 2017

Abraham, M.: Encyclopedia of Sustainable Technologies. 1 Aufl. Saint Louis: Elsevier Science 2017. ISBN: 0128047925.

ALPAR & NIEDEREICHHOLZ 2000

Alpar, P.; Niedereichholz, J.: Data Mining im praktischen Einsatz. Verfahren und Anwendungsfälle für Marketing, Vertrieb, Controlling und Kundenunterstützung. Wiesbaden: Vieweg+Teubner Verlag 2000. ISBN: 978-3-528-05748-0. (Business Computing).

ANAND ET AL. 1995

Anand, S. S.; Bell, D. A.; Hughes, J. G.: The role of domain knowledge in data mining. In: Pissinou, N. (Hrsg.): Proceedings of the fourth international conference on Information and knowledge management, the fourth international conference. Baltimore, Maryland, United States, 11/29/1995 - 12/2/1995. New York, NY: ACM 1995, S. 37-43. ISBN: 0897918126.

ANSCOMBE 1981

Ancombe, F. J.: Computing in Statistical Science through APL. New York, NY: Springer 1981. ISBN: 978-1-4613-9452-5. (Springer Series in Statistics).

APPELFELLER & FELDMANN 2018

Appelfeller, W.; Feldmann, C.: Die digitale Transformation des Unternehmens. Systematischer Leitfaden mit zehn Elementen zur Strukturierung und Reifegradmessung. Berlin: Springer Gabler 2018. ISBN: 9783662540619.

ASMA ET AL. 2014

Asma, A. S.; Shahzad, M. K.; Zamai, E.; Hubac, S.: Methodology for integrated failure-cause diagnosis with Bayesian Approach: Application to semiconductor manufacturing equipment (2014) Vol. 5, S. 71-82.

**BANKHOFER & VOGEL 2008**

Bankhofer, U.; Vogel, J.: Datenanalyse und Statistik. Eine Einführung für Ökonomen im Bachelor. Wiesbaden: Betriebswirtschaftlicher Verlag Dr. Th. Gabler / GWV Fachverlage GmbH Wiesbaden 2008. ISBN: 3834904341.

**BARTELS 2009**

Barfels, Andreas (Hrsg.): Wissenschaftstheorie. Ein Studienbuch. 2. Aufl. Paderborn: mentis-Verl. 2009. ISBN: 978-3-89785-591-5.

**BEIERLE & KERN-ISBERNER 2008**

Beierle, C.; Kern-Isberner, G.: Methoden wissensbasierter Systeme: Grundlagen, Algorithmen, Anwendungen: Vieweg+Teubner Verlag 2008. ISBN: 9783834805041.

**BOX & COX 1982**

Box, G. E.; Cox, D. R.: An Analysis of Transformations Revisited, Rebutted. Journal of the American Statistical Association 77 (1982) 377, S. 209-210.

**BRACKE 2016**

Bracke, S.: Prozessfähigkeit bei der Herstellung komplexer technischer Produkte. Statistische Mess- und Prüfdatenanalyse. 1. Aufl. Berlin, Heidelberg: Springer Vieweg 2016. ISBN: 9783662482131.

**BRODD & HELOU 2013**

Brodd, R. J.; Helou, C.: Cost comparison of producing high-performance Li-ion batteries in the U.S. and in China. Journal of Power Sources 231 (2013), S. 293-300.

**BROWNING 2001**

Browning, T. R.: Applying the design structure matrix to system decomposition and integration problems: a review and new directions. IEEE Transactions on Engineering Management 48 (2001) 3, S. 292-306.

**BRÜGGEMANN & BREMER 2015**

Brüggemann, H.; Bremer, P.: Grundlagen Qualitätsmanagement. Von den Werkzeugen über Methoden zum TQM. 2. Aufl. Wiesbaden: Springer Vieweg 2015. ISBN: 978-3-658-09221-4. (Lehrbuch).

**BUNDESMINISTERIUM FÜR UMWELT, NATURSCHUTZ UND NUKLEARE SICHERHEIT 2019**

Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit: Wie umweltfreundlich sind Elektroautos? Eine ganzheitliche Bilanz. <[https://www.bmu.de/fileadmin/Daten\\_BMU/Pool/Broschueren/elektroautos\\_bf.pdf](https://www.bmu.de/fileadmin/Daten_BMU/Pool/Broschueren/elektroautos_bf.pdf)> - 07.04.2020.

BURDENSKY ET AL. 2018

Burdensky, D.; Kneissl, B.; Alt, R.: Deskriptive Analyse von Kennzahlenrelationen. Universität Leipzig. Leipzig (2018) - 20.09.2018.

CAO & ZHANG 2008

Cao, L.; Zhang, C.: Domain-Driven Data Mining. In: IGI Global (Hrsg.): Data warehousing and mining. Concepts, methodologies, tools, and applications. Hershey, Pa: IGI Global (701 E. Chocolate Avenue Hershey Pennsylvania 17033 USA) 2008, S. 49-65. ISBN: 978-1-59904-951-9.

CAO 2010

Cao, L.: Domain Driven Data Mining. Dordrecht: Springer 2010. ISBN: 978-1-4419-5736-8.

CAO 2012

Cao, L.: Actionable knowledge discovery and delivery. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery 2 (2012) 2, S. 149-163.

CHAN ET AL. 1988

Chan, L. K.; Cheng, S. W.; Spiring, F. A.: A New Measure of Process Capability: C<sub>pm</sub>. Journal of Quality Technology 20 (1988) 3, S. 162-175.

CHANG ET AL. 2014

Chang, J.-F.; Tsai, P.-W.; Chen, J.-F.; Hsiao, C.-T.: The Comparison between IABC with EGARCH in Foreign Exchange Rate Forecasting. In: Pan, J.-S. et al. (Hrsg.): Intelligent Data analysis and its Applications, Volume II. Cham: Springer International Publishing 2014, S. 127-136. ISBN: 978-3-319-07772-7. (Advances in Intelligent Systems and Computing).

CLEFF 2015

Cleff, T.: Deskriptive Statistik und Explorative Datenanalyse. Eine computergestützte Einführung mit Excel, SPSS und STATA. Wiesbaden: Gabler Verlag 2015. ISBN: 978-3-8349-4748-2.

COSKUN ET AL. 2019

Coskun, A.; Serteser, M.; Ünsal, I.: Sigma metric revisited: True known mistakes. Biochemia medica 29 (2019) 1.

DEB ET AL. 2004

Deb, K.; Poli, R.; Banzhaf, W.; Beyer, H. G.; Burke, E.; Darwen, P.; Dasgupta, D.; Floreano, D.; Foster, J. A.; Harman, M.: Genetic and Evolutionary Computation — GECCO 2004: Genetic and Evolutionary Computation Conference Seattle, WA, USA, June 26–30, 2004, Proceedings: Springer Berlin Heidelberg 2004. ISBN: 9783540248545. (Teil 1).

DE-FELIPE & BENEDITO 2017

de-Felipe, D.; Benedito, E.: Minimizing rework costs in multistage production processes by modifying quality specification limits. (Hrsg.): 2017 IEEE International Conference on Industrial Technology (ICIT). Toronto, ON, 22.03.2017 - 25.03.2017: IEEE 2017, S. 831-836. ISBN: 978-1-5090-5320-9.

DE-FELIPE & BENEDITO 2017

de-Felipe, D.; Benedito, E.: Monitoring high complex production processes using process capability indices. The International Journal of Advanced Manufacturing Technology 93 (2017b) 1-4, S. 1257-1267.

DE-FELIPE 2017

de-Felipe, D.: Management of Production Systems Using Process Capability Indices in the Context of Industry 4.0. (Dissertation). Department of Business Administration and Management, Escola Tecnica Superior d'Enginyeria Industrial de Barcelona (2017).

DEHMER ET AL. 2011

Dehmer, M.; Emmert-Streib, F.; Graber, A.; Salvador, A.: Applied Statistics for Network Biology: Methods in Systems Biology: Wiley 2011. ISBN: 9783527638086.

DÉR ET AL. 2018

Dér, A.; Erkisi-Arici, S.; Stachura, M.; Cerdas, F.; Böhme, S.; Herrmann, C.: Life Cycle Assessment of Electric Vehicles in Fleet Applications. In: Herrmann, C. et al. (Hrsg.): Fleets Go Green. Cham: Springer International Publishing 2018, S. 61-80. ISBN: 978-3-319-72723-3. (Sustainable Production, Life Cycle Engineering and Management).

DIALLO ET AL. 2018

Diallo, T. M.; Henry, S.; Ouzrout, Y.; Bouras, A.: Data-Based Fault Diagnosis Model Using a Bayesian Causal Analysis Framework. International Journal of Information Technology & Decision Making 17 (2018) 02, S. 583-620.

DÍEZ 1993

Díez, F. J.: Parameter adjustment in Bayes networks. The generalized noisy-ORgate. In: Heckerman, D. et al. (Hrsg.): Uncertainty in Artificial Intelligence: Elsevier 1993, S. 99-105. ISBN: 9781483214511. (Proceedings of the Ninth international conference on Uncertainty in artificial intelligence).

DIN EN ISO 9000

DIN EN ISO 9000: 9000:2005. Berlin: Beuth 2019-10.

DIN EN ISO 9004 2018-4

DIN EN ISO 9004 2018-4: 9004 2018-4. Berlin: Beuth 2018-4.

DIN EN 60812 2015-08

DIN EN 60812 2015-08: 60812 2015-08. Berlin: Beuth 2015-08.

DIN 55350-11

DIN 55350-11: 55350-11. Berlin: Beuth 2008-05.

DÖBEL ET AL. 2018

Döbel, I.; Leis, M.; Vogelsang, M.; Neustroev, D.; Petzka, H.; Rüpig, S.; Voss, A.; Wegele, M.; Welz, Julian: Maschinelles Lernen. Kompetenzen, Anwendungen und Forschungsbedarf. Fraunhofer-Gesellschaft (2018), S. 1-202.

DORMANN 2017

Dormann, C. F.: Parametrische Statistik. Verteilungen, maximum likelihood und GLM in R. 2. Aufl. Berlin, Heidelberg: Springer Spektrum 2017. ISBN: 978-3-662-54683-3. (Statistik und ihre Anwendungen).

DREGER ET AL. 2015

Dreger, H.; Bockholt, H.; Haselrieder, W.; Kwade, A.: Discontinuous and Continuous Processing of Low-Solvent Battery Slurries for Lithium Nickel Cobalt Manganese Oxide Electrodes. Journal of Electronic Materials 44 (2015) 11, S. 4434-4443.

DU ET AL. 2020

Du, M.; Liu, N.; Hu, X.: Techniques for interpretable machine learning. Communications of the ACM 63 (2020) 1, S. 68-77.

DYCKHOFF ET AL. 2012

Dyckhoff, H.; Müser, M.; Renner, T.: Ansätze einer Produktionstheorie des Serienanlaufs. Zeitschrift für Betriebswirtschaft 82 (2012) 12, S. 1427-1456.

EICHGRÜN 2003

Eichgrün, K.: Prozesssicherheit in fertigungstechnischen Prozessketten. (Dissertation) Universität Kaiserslautern. Kaiserslautern (2003).

ELSHAWI ET AL. 2019

Elshawi, R.; Al-Mallah, M. H.; Sakr, S.: On the interpretability of machine learning-based model for predicting hypertension. BMC medical informatics and decision making 19 (2019) 1.

ERK 2016

Erk, C.: Was ist ein System? Eine Einführung in den klassischen Systembegriff. Universität St. Gallen. Münster: LIT Verlag Münster 2016. ISBN: 9783643802033. (Red Guide).



ESCALANTE ET AL. 2018

Escalante, H.; Escalera, S.; Guyon, I.; Baró, X.; van Gerven, M. (Hrsg.): Explainable and Interpretable Models in Computer Vision and Machine Learning. Cham: Springer International Publishing 2018. ISBN: 9783319981314. (The Springer Series on Challenges in Machine Learning).

ESCHEY 2013

Eschey, C.: Maschinenspezifische Erhöhung der Prozessfähigkeit in der additiven Fertigung. Institut für Werkzeugmaschinen und Betriebswissenschaften der Technischen Universität München. München: Herbert Utz Verlag, 2013.

FABIŚ-DOMAGAŁA ET AL. 2019

Fabiś-Domagala, J.; Momeni, H.; Domagala, M.; Filo, G.: Matrix Fmea Analysis as a Preventive Method for Quality Design of Hydraulic Components. System Safety: Human - Technical Facility - Environment 1 (2019) 1, S. 684-691.

FAYYAD ET AL. 1996

Fayyad, U.; Piatetsky-Shapiro, G.; Smyth, P.: From Data Mining to Knowledge Discovery in Databa. AI Magazine 96 (1996) 17, S. 38-54.

FEURER ET AL. 2015

Feurer, M.; Klein, A.; Eggenberger, K.; Springenberg, J.; Blum, M.; Hutter, F.: Efficient and Robust Automated Machine Learning. In: C. Cortes et al. (Hrsg.): Advances in Neural Information Processing Systems 28: Curran Associates, Inc 2015, S. 2962-2970.

FILZ ET AL. 2020

Filz, M.-A.; Gellrich, S.; Turetsky, A.; Wessel, J.; Herrmann, C.; Thiede, S.: Virtual Quality Gates in Manufacturing Systems: Framework, Implementation and Potential. Journal of Manufacturing and Materials Processing 4 (2020) 4, S. 106.

FLEISCHER ET AL. 2005

Fleischer, J.; Lanza, G.; Ender, T.: Prozessinnovation durch prozessbasierte Qualitätsprognose im Produktionsanlauf. ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb 100 (2005) 9, S. 510-516.

FORSCHUNGSSTELLE FÜR ENERGIEWIRTSCHAFT 2019

Forschungsstelle für Energiewirtschaft: Klima- und Ressourcenwirkung von Elektrofahrzeugbatterien. 2019.

FREITAG ET AL. 2015

Freitag, M.; Kück, M.; Ait Alla, A.; Lütjen, M.: Potenziale von Data Science in Produktion und

Logistik: Teil 2 - Vorgehensweise zur Datenanalyse und Anwendungsbeispiele. Industrie 4.0 Management 35 (2015), S. 39-46.

FUSI ET AL. 2017

Fusi, N.; Sheth, R.; Elibol, H. M.: Probabilistic Matrix Factorization for Automated Machine Learning. 32nd Conference on Neural Information Processing Systems (NeurIPS 2018), Montréal, Canada.: 15.05.2017.

GABRIEL ET AL. 2012

Gabriel, M.-O.; Lung, B.; Barberá, L.; Viveros, P.: Root cause analysis to identify physical causes. 11th International Probabilistic Safety Assessment and Management (2012).

GAROUFALLOU ET AL. 2019

Garoufallou, E.; Fallucchi, F.; Ernesto, W. D.: Metadata and Semantic Research. 13th International Conference, MTSR 2019, Rome, Italy, October 28–31, 2019, Revised Selected Papers. 1. Aufl: 2019. ISBN: 3030365999. (Communications in Computer and Information Science).

GEIGER & KOTTE 2008

Geiger, W.; Kotte, W.: Handbuch Qualität. Grundlagen und Elemente des Qualitätsmanagements: Systeme, Perspektiven. 5. Aufl. Wiesbaden: Friedr. Vieweg & Sohn Verlag | GWV Fachverlage GmbH Wiesbaden 2008. ISBN: 978-3-8348-9429-8. (Praxis und Studium).

GEITNER 2013

Geitner, U. W.: CIM-Handbuch: Wirtschaftlichkeit durch Integration. Wiesbaden: Vieweg+Teubner Verlag 2013. ISBN: 9783322835314.

GELLRICH ET AL. 2019

Gellrich, S.; Filz, M.-A.; Wölper, J.; Herrmann, C.; Thiede, S.: Data-Mining Application in Manufacturing of Lightweight Structure. In: Dröder, K. et al. (Hrsg.): Technologies for economical and functional lightweight design. Berlin, Heidelberg: Springer Berlin Heidelberg 2019, S. 15-27. ISBN: 978-3-662-58205-3. (Zukunftstechnologien für den multifunktionalen Leichtbau).

GHAVAMI 2019

Ghavami, P.: Big Data Analytics Methods. Analytics Techniques in Data Mining, Deep Learning and Natural Language Processing. 1. Band Aufl: Walter de Gruyter GmbH & Co KG, 2019.

GIEBLER ET AL. 2019

Giebler, C.; Gröger, C.; Hoos, E.; Schwarz, H.; Mitschang, B.: Leveraging the Data Lake: Current State and Challenges. In: Ordonez, C. et al. (Hrsg.): Big Data Analytics and

Knowledge Discovery. Cham: Springer International Publishing 2019, S. 179-188.  
ISBN: 978-3-030-27519-8. (Lecture Notes in Computer Science).

GLEICH ET AL. 2012

Gleich, C. F. von; Schütt, A.; Isenberg, R.: SMART ramp-up: methods to secure production ramp-up in the aircraft industry. CEAS Aeronautical Journal 3 (2012) 2-4, S. 125-134.

GLEICH ET AL. 2017

Gleich, R.; Grönke, K.; Kirchmann, M.; Leyk, J.: Strategische Unternehmensführung mit Advanced Analytics. Neue Möglichkeiten von Big Data für Planung und Analyse erkennen und nutzen. München: Haufe Lexware Verlag 2017. ISBN: 9783648104231. (Haufe Fachbuch v.11430).

GOSIEWSKA ET AL. 2019

Gosiewska, A.; Gacek, A.; Lubon, P.; Biecek, P.: SAFE ML: Surrogate Assisted Feature Extraction for Model Learning. 28.02.2019.

GRÖGER 2015

Gröger, C.: Advanced Manufacturing Analytics. Datengetriebene Optimierung von Fertigungsprozessen. 1. Aufl. Lohmar, Köln: Eul-Verl. 2015. ISBN: 9783844104202.

GRÖGER ET AL. 2012

Gröger, C.; Schlaudraff, J.; Niedermann, F.; Mitschang, B.: Warehousing Manufacturing Data. In: Hutchison, D. et al. (Hrsg.): Data Warehousing and Knowledge Discovery. Berlin, Heidelberg: Springer Berlin Heidelberg 2012, S. 142-155. ISBN: 978-3-642-32583-0. (Lecture Notes in Computer Science).

GRÖGER ET AL. 2013

Gröger, C.; Hillmann, M.; Hahn, F.; Mitschang, B.; Westkämper, E.: The Operational Process Dashboard for Manufacturing. Procedia CIRP 7 (2013), S. 205-210.

GRÖGER ET AL. 2014

Gröger, C.; Schwarz, H.; Mitschang, B.: The Deep Data Warehouse: Link-Based Integration and Enrichment of Warehouse Data and Unstructured Content. In: Grossmann, G. (Hrsg.): 2014 IEEE 18th International Enterprise Distributed Object Computing Conference workshops and demonstrations (EDOCW), 2014 IEEE 18th International Enterprise Distributed Object Computing Conference (EDOC 2014). Ulm, Germany, 9/1/2014 - 9/5/2014. Piscataway, NJ: IEEE 2014, S. 210-217. ISBN: 978-1-4799-5470-4.

GRÖGER ET AL. 2014

Gröger, C.; Schwarz, H.; Mitschang, B.: The Manufacturing Knowledge Repository. Consolidating Knowledge to Enable Holistic Process Knowledge Management in Manufacturing (2014b).

GROßMANN & WIEMER 2010

Großmann, K.; Wiemer, H.: Reproduzierbare Fertigung in innovativen Prozessketten. ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb 105 (2010) 10, S. 855-859.

GROSSMANN 2014

GROSSMANN: 2014 IEEE 18th International Enterprise Distributed Object Computing Conference workshops and demonstrations (EDOCW), 2014 IEEE 18th International Enterprise Distributed Object Computing Conference (EDOC 2014). Ulm, Germany, 9/1/2014 - 9/5/2014. Piscataway, NJ: IEEE 2014. ISBN: 978-1-4799-5470-4.

GROßMANN ET AL. 2012

Großmann, K.; Wiemer, H.; Helbig, M.: Modellierung und Analyse technologischer Ketten. Ein neuer Ansatz zur effektiven Generierung von Technologiewissen. Industrie Management 28 (2012) 28, S. 38-42.

GROßMANN ET AL. 2013

Großmann, K.; Wiemer, H.; Großmann, K. K.: Methods for Modelling and Analysing Process Chains for Supporting the Development of New Technologies. Procedia Materials Science 2 (2013), S. 34-42.

GÜNTER ET AL. 2020

Günter, F. J.; Rössler, S.; Schulz, M.; Braunwarth, W.; Gilles, R.; Reinhart, G.: Influence of the Cell Format on the Electrolyte Filling Process of Lithium-Ion Cells. Energy Technology 8 (2020) 2.

GUTZMER & TODSEN 2019

Gutzmer, P.; Todsén, E.: Motivation. In: Tschöke, H. et al. (Hrsg.): Elektrifizierung des Antriebsstrangs. Berlin, Heidelberg: Springer Berlin Heidelberg 2019, S. 3-16. ISBN: 978-3-662-60355-0.

HALFORD ET AL. 2005

Halford, G. S.; Baker, R.; McCredén, J. E.; Bain, J. D.: How many variables can humans process? Psychological science 16 (2005) 1, S. 70-76.

HANISCH ET AL. 2015

Hanisch, C.; Schunemann, J.-H.; Diekmann, J.; Westphal, B.; Loellhoeffel, T.; Prziwara, P.

F.; Haselrieder, W.; Kwade, A.: In-Production Recycling of Active Materials from Lithium-Ion Battery Scraps. ECS Transactions 64 (2015) 22, S. 131-145.

HECKERMAN & BREESE 1996

Heckerman, D.; Breese, J. S.: Causal independence for probability assessment and inference using Bayesian networks. IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans 26 (1996) 6, S. 826-831.

HEINRICH 2019

Heinrich, B.: Grundlagen Automatisierung. Erfassen - steuernregeln. [S.l.]: MORGAN KAUFMANN 2019. ISBN: 9783658273224.

HESSE 2003

Hesse, C.: Angewandte Wahrscheinlichkeitstheorie. Eine fundierte Einführung mit über 500 realitätsnahen Beispielen und Aufgaben. Wiesbaden, s.l.: Vieweg+Teubner Verlag 2003. ISBN: 978-3-663-01244-3.

HOLLAND & KARTER 2019

Holland, M.; Karter, T.: Understanding & Applying Basic Statistical Methods Using R: Scientific e-Resources 2019. ISBN: 9781839473371.

HUANG ET AL. 2008

Huang, Y.; McMurran, R.; Dhadyalla, G.; Peter Jones, R.: Probability based vehicle fault diagnosis: Bayesian network method. Journal of Intelligent Manufacturing 19 (2008) 3, S. 301-311.

HÜGENS 2009

Hügens, T.: Balanced Scorecard und Ursache-Wirkungsbeziehungen. Wiesbaden: Springer Fachmedien 2009. ISBN: 9783834981714. (Information - Organisation - Produktion).

HUTCHISON ET AL. 2010

Hutchison, D.; Kanade, T.; Kittler, J.; Kleinberg, J. M.; Mattern, F.; Mitchell, J.; Naor, M.; Nierstrasz, O.; Pandu Rangan, C.; Steffen, B.; Sudan, M.; Terzopoulos, D.; Tygar, D.; Vardi, M. Y.; Weikum, G.; Setchi, R.; Jordanov, I.; Howlett, R. J.; J., Lakhmi C. (Hrsg.): Knowledge-Based and Intelligent Information and Engineering Systems. Berlin, Heidelberg: Springer 2010. ISBN: 978-3-642-15389-1. (Lecture Notes in Computer Science).

HUTTER ET AL. 2019

Hutter, Frank; Kotthoff, Lars; Vanschoren, Joaquin (Hrsg.): Automated Machine Learning. Cham: Springer International Publishing 2019. ISBN: 978-3-030-05317-8. (The Springer Series on Challenges in Machine Learning).

IDE & COZMAN 2008

Ide, J. S.; Cozman, F. G.: Approximate algorithms for credal networks with binary variables. *International Journal of Approximate Reasoning* 48 (2008) 1, S. 275-296.

INTERNATIONAL ENERGY AGENCY 2019

International Energy Agency (IEA): Electric vehicles. <<https://www.iea.org/reports/global-ev-outlook-2019>> - 07.04.2020.

INTERNATIONAL ENERGY AGENCY 2019

International Energy Agency (IEA): Global EV Outlook 2019. <<https://www.iea.org/reports/global-ev-outlook-2019>> - 07.04.2020.

ISO 22400-1

ISO 22400-1, 25.040.01: 22400. Berlin: Beuth 2014-01.

JESSENBERGER & WEIHS 2005

Jessenberger, J.; Weihs, C.: Desirability to Characterize Process Capability. In: Weihs, C. et al. (Hrsg.): *Classification — the Ubiquitous Challenge*. Berlin/Heidelberg: Springer-Verlag 2005, S. 640-647. ISBN: 3-540-25677-6. (Studies in Classification, Data Analysis, and Knowledge Organization).

JESSENBERGER 1999

Jessenberger, J.: *Prozeßfähigkeitsindizes in der Qualitätssicherung*. (Dissertation). Statistik, Technische Universität Dortmund. Dortmund (1999).

JOHN & MISRA 2017

John, T.; Misra, P.: *Data Lake for enterprises. Leveraging Lambda architecture for building Enterprise Data Lake*. Birmingham, UK: Packt Publishing 2017. ISBN: 9781787282650.

JUNG & WINTER 2000

Jung, R.; Winter, R.: *Data Warehousing Strategie. Erfahrungen, Methoden, Visionen*. Berlin, Heidelberg: Springer 2000. ISBN: 9783642583506. (Business Engineering).

KABIR ET AL. 2016

Kabir, G.; Sadiq, R.; Tesfamariam, S.: A fuzzy Bayesian belief network for safety assessment of oil and gas pipelines. *Structure and Infrastructure Engineering* 12 (2016) 8, S. 874-889.

KALUZA ET AL. 2018

Kaluza, A.; Gellrich, S.; Cerdas, F.; Thiede, S.; Herrmann, C.: Life Cycle Engineering Based on Visual Analytics. *Procedia CIRP* 69 (2018), S. 37-42.

KAMPKER 2014

Kampker, A.: Elektromobilproduktion. Berlin: Springer Vieweg 2014. ISBN: 978-3-642-42021-4.

KAMPKER ET AL. 2013

Kampker, A.; Hohenthanner, C.-R.; Deutskens, C.; Heimes, H. H.; Sesterheim, C.: Fertigungsverfahren von Lithium-Ionen-Zellen und -Batterien. In: Korthauer, R. (Hrsg.): Handbuch Lithium-Ionen-Batterien. Berlin, Heidelberg, s.l.: Springer 2013, S. 237-247. ISBN: 978-3-642-30652-5.

KÄPPLER ET AL. 2014

Käppler, W. D.; Pressler, R. K.; Siebel, M.; Specht, D.: Smart Safety Management mit Ariadne SMS: Springer Berlin Heidelberg 2014. ISBN: 9783642552519.

KATZ ET AL. 2016

Katz, G.; Shin, E. C.; Song, D.: ExploreKit: Automatic Feature Generation and Selection. (Hrsg.): 2016 IEEE 16th International Conference on Data Mining (ICDM) 2016, S. 979-984.

KELEMEN ET AL. 2008

Kelemen, A.; Abraham, A.; Liang, Y.: Computational Intelligence in Medical Informatics: Springer Berlin Heidelberg 2008. ISBN: 9783540757672.

KEPSKI & KWOLEK 2013

Kepski, M.; Kwolek, B.: Unobtrusive Fall Detection at Home Using Kinect Sensor. In: Hutchison, D. et al. (Hrsg.): Computer Analysis of Images and Patterns. Berlin, Heidelberg: Springer Berlin Heidelberg 2013, S. 457-464. ISBN: 978-3-642-40260-9. (Lecture Notes in Computer Science).

KESSLER & GÓMEZ 2020

Kessler, R.; Gómez, J. M.: Implikationen von Machine Learning auf das Datenmanagement in Unternehmen. HMD Praxis der Wirtschaftsinformatik 57 (2020) 1, S. 89-105.

KIRCHHOF ET AL. 2020

Kirchhof, M.; Haas, K.; Kornas, T.; Thiede, S.; Hirz, M.; Herrmann, C.: Failure Analysis in Lithium-Ion Battery Production with FMEA-Based Large-Scale Bayesian Network. MDPI Batteries (2020).

KLEPPMANN 2011

Kleppmann, W.: Taschenbuch Versuchsplanung. Produkte und Prozesse optimieren. 7. Aufl. München: Hanser 2011. ISBN: 978-3-446-42774-7. (Praxisreihe Qualitätswissen).

## KLOSTERMANN 2008

Klostermann, T.: Optimierung kooperativer Dienstleistungen im Technischen Kundendienst des Maschinenbaus. Wiesbaden: Betriebswirtschaftlicher Verlag Dr. Th. Gabler / GWV Fachverlage GmbH Wiesbaden 2008. ISBN: 978-3-8349-0903-9. (Gabler Edition Wissenschaft).

## KMENTA &amp; ISHII 2004

Kmenta, S.; Ishii, K.: Scenario-Based Failure Modes and Effects Analysis Using Expected Cost. *Journal of Mechanical Design* 126 (2004) 6, S. 1027-1035.

## KNOCHE 2017

Knoche, T.: Elektrolytbefüllung prismatischer Lithium-Ionen-Zellen. München: Utz, Herbert 2017. (Forschungsberichte IWB).

## KÖHLER 2008

Köhler, J.: Wissenstransfer bei hoher Produkt- und Prozesskomplexität. Pilotierung, Rollout und Migration neuer Methoden am Beispiel der Automobilindustrie. (Zugl.: Hohenheim, Univ., Diss., 2007). Wiesbaden: Betriebswirtschaftlicher Verlag Dr. Th. Gabler / GWV Fachverlage GmbH Wiesbaden 2008. ISBN: 978-3-8349-0923-7. (Gabler Edition Wissenschaft).

## KORNAS ET AL. 2019

Kornas, T.; Daub, R.; Karamat, M. Z.; Thiede, S.; Herrmann, C.: Data-and Expert-Driven Analysis of Cause-Effect Relationships in the Production of Lithium-Ion Batteries. 2019 IEEE 15th International Conference on Automation Science and Engineering (CASE) (2019a), S. 380-385.

## KORNAS ET AL. 2019

Kornas, T.; Knak, E.; Daub, R.; Bühner, U.; Lienemann, C.; Heimes, H.; Kampker, A.; Thiede, S.; Herrmann, Christoph: A Multivariate KPI-Based Method for Quality Assurance in Lithium-Ion-Battery Production. *Procedia CIRP* 81 (2019b), S. 75-80.

## KORNAS ET AL. 2020

Kornas, T.; Wittmann, D.; Daub, R.; Meyer, O.; Weihs, C.; Thiede, S.; Herrmann, C.: Multi-Criteria Optimization in the Production of Lithium-Ion Batteries. *Procedia Manufacturing* (2020).

## KOSFELD ET AL. 2016

Kosfeld, R.; Eckey, H.-F.; Türck, M.: Deskriptive Statistik. Grundlagen - Methoden - Beispiele - Aufgaben. Springer Fachmedien Wiesbaden GmbH. 6. Aufl. Wiesbaden: Springer Gabler 2016. ISBN: 9783658136406. (Lehrbuch).

## KUBLER ET AL. 2017

Kubler, K.; Verl, A.; Riedel, O.; Oberle, M.: Simulation-assisted run-to-run control for battery



manufacturing in a cloud environment. (Hrsg.): 2017 24th International Conference on Mechatronics and Machine Vision in Practice (M2VIP). Auckland, 21.11.2017 - 23.11.2017: IEEE 2017, S. 1-6. ISBN: 978-1-5090-6546-2.

KWADE ET AL. 2018

Kwade, A.; Haselrieder, W.; Leithoff, R.; Modlinger, A.; Dietrich, F.; Droeder, K.: Current status and challenges for automotive battery production technologies. *Nature Energy* 3 (2018) 4, S. 290-300.

LEE 2001

Lee, B. H.: Using Bayes belief networks in industrial FMEA modeling & analysis. In: Reliability and Maintainability Symposium et al. (Hrsg.): Annual Reliability and Maintainability Symposium. Piscataway, N.J: Institute of Electrical and Electronics Engineers 2001, S. 7-15. ISBN: 0780366166.

LEUTHNER 2013

Leuthner, S.: Übersicht zu Lithium-Ionen-Batterien. In: Korthauer, R. (Hrsg.): Handbuch Lithium-Ionen-Batterien. Berlin, Heidelberg, s.l.: Springer 2013, S. 13-19. ISBN: 978-3-642-30652-5.

LEVANDOSKI ET AL. 2013

Levandoski, J. J.; Larson, P.-A.; Stoica, R.: Identifying hot and cold data in main-memory databases. (Hrsg.): 2013 IEEE 29th International Conference on Data Engineering (ICDE). Brisbane, QLD, 08.04.2013 - 12.04.2013: IEEE, S. 26-37. ISBN: 978-1-4673-4910-9.

LI & SHI 2007

Li, J.; Shi, J.: Knowledge discovery from observational data for process control using causal Bayesian networks. *IIE Transactions* 39 (2007) 6, S. 681-690.

LINß 2013

Linß, G.: Qualitätsmanagement für Ingenieure. 3. Aufl. München: Hanser Carl 2013. ISBN: 978-3-446-42809-6.

LIU & CHEN 2006

Liu, P.-H.; Chen, F.-L.: Process capability analysis of non-normal process data using the Burr XII distribution. *The International Journal of Advanced Manufacturing Technology* 27 (2006) 9-10, S. 975-984.

MA ET AL. 2014

Ma, D. Z.; Ding, W. F.; Jiang, Y. Q.; Zhou, Z.: Constructing Reliability Analysis Model of Complex Systems Based on FMEA-FTA-BN. *Advanced Materials Research* 945-949 (2014), S. 1042-1045.

MCNAUGHT & CHAN 2011

McNaught, K.; Chan, A.: Bayesian networks in manufacturing. *Journal of Manufacturing Technology Management* 22 (2011) 6, S. 734-747.

MEYER ET AL. 2019

Meyer, O.; Weihs, C.; Mähr, S.; Tran, H. Y.; Kirchhof, M.; Schnackenberg, S.; Neuhaus-Stern, J.; Rößler, S.; Braunwarth, Wolfgang: Development and implementation of statistical methods for quality optimization in the large-format lithium-ion cells production. *Energy Technology* (2019).

MOLLENHAUER 2007

Mollenhauer, J.-P.: Design for Six Sigma+Lean toolset. Innovationen erfolgreich realisieren. Berlin, Heidelberg, New York: Springer 2007. ISBN: 978-3-540-69714-5.

MÜLLER 2010

Müller, J.: Entwicklung eines Qualitätskennzahlensystems für die Fahrzeuginstandhaltung. (Dissertation). [Place of publication not identified]: Grin Verlag 2010. ISBN: 9783640611065.

MÜLLER ET AL. 2020

Müller, A.; Graumann, M.; Weiß, H.-J.: Innovationen für eine digitale Wirtschaft. Wie Unternehmen den Wandel meistern. 1. Aufl: 2020. ISBN: 9783658290276. (Business - Innovation - High Tech).

MURDOCH ET AL. 2019

Murdoch, W. J.; Singh, C.; Kumbier, K.; Abbasi-Asl, R.; Yu, B.: Interpretable machine learning: definitions, methods, and applications. *Proceedings of the National Academy of Sciences* 116 (2019) 44, S. 22071-22080.

NAGEL 2011

Nagel, J.: Risikoorientiertes Anlaufmanagement. (Zugl.:Cottbus, Brandenburgische Techn. Univ., Diss., 2010). 1. Aufl. Wiesbaden: Springer 2011. ISBN: 978-3-8349-3087-3. (Beiträge zur Produktionswirtschaft).

NATIONALE PLATTFORM ELEKTROMOBILITÄT 2016

Nationale Plattform Elektromobilität (NPE): Roadmap integrierte Zell- und Batterieproduktion Deutschland. AG 2- Batterietechnologie. <[http://nationale-plattform-elektromobilitaet.de/fileadmin/user\\_upload/Redaktion/Publikationen/AG2\\_Roadmap\\_Zellfertigung\\_eng\\_bf.pdf](http://nationale-plattform-elektromobilitaet.de/fileadmin/user_upload/Redaktion/Publikationen/AG2_Roadmap_Zellfertigung_eng_bf.pdf)>.

NELSON ET AL. 2019

Nelson, P.; Ahmed, S.; Gallagher, K.; Dees, D.: Modeling the Performance and Cost of Lithium-Ion Batteries for Electric-Drive Vehicles. 1. Aufl. Alexandria: 2019.

NIAKI & ABBASI 2007

Niaki, S. T.; Abbasi, B.: Skewness Reduction Approach in Multi-Attribute Process Monitoring. *Communications in Statistics - Theory and Methods* 36 (2007) 12, S. 2313-2325.

OBDENBUSCH 2018

Obdenbusch, M.: Referenzarchitektur für cloudbasiertes Condition Monitoring am Beispiel von Verpackungsmaschinen. 1. Aufl. Aachen: Apprimus Wissenschaftsverlag 2018. ISBN: 9783863595814.

OHRI 2018

Ohri, A.: Python® for R users. A data science approach. Hoboken, NJ: John Wiley & Sons Inc 2018. ISBN: 9781119126768.

OLIVA ET AL. 2010

Oliva, G. M.; Weber, P.; Levrat, E.; Iung, B.: Use of Probabilistic Relational Model (PRM) for Dependability Analysis of Complex Systems. *IFAC Proceedings Volumes* 43 (2010) 8, S. 501-506.

PATHAK 2014

Pathak, M. A.: *Beginning data science with R*. Cham: Springer 2014. ISBN: 9783319120669.

PERNER 2007

Perner, P.: *Advances in Data Mining - Theoretical Aspects and Applications: 7th Industrial Conference, ICDM 2007, Leipzig, Germany, July 14-18, 2007, Proceedings*: Springer Berlin Heidelberg 2007. ISBN: 9783540734352.

PETERSOHN 2009

Petersohn, H.: *Data Mining. Verfahren, Prozesse, Anwendungsarchitektur*. (Zugl.: Leipzig, Univ., Habil, 2004). München, Wien: Oldenbourg 2009. ISBN: 9783486577150.

PETTINGER 2013

Pettinger, K.-H.: *Fertigungsprozesse von Lithium-Ionen-Zellen*. In: Korthauer, R. (Hrsg.): *Handbuch Lithium-Ionen-Batterien*. Berlin, Heidelberg, s.l.: Springer 2013, S. 221-235. ISBN: 978-3-642-30652-5.

POHLHEIM 2013

Pohlheim, H.: *Evolutionäre Algorithmen: Verfahren, Operatoren und Hinweise für die Praxis*: Springer Berlin Heidelberg 2013. ISBN: 9783642571374.

POURRET ET AL. 2008

Pourret, O.; Naïm, P.; Marcot, B.: *Bayesian Networks: A Practical Guide to Applications*: Wiley 2008. ISBN: 9780470060308.

PROBST & GOMEZ 1991

Probst, Gilbert J. B.; Gomez, Peter (Hrsg.): Vernetztes Denken. Ganzheitliches Führen in der Praxis. 2., erweiterte Auflage Aufl. Wiesbaden: Gabler 1991. ISBN: 978-3-322-89073-3.

RASHIDY 2007

Rashidy, H.: Knowledge-based quality control in manufacturing processes with application to the automotive industry. (Zugl.: München, Techn. Univ., Diss., 2008). München: Utz 2007. ISBN: 978-3-8316-0862-1. (Forschungsberichte IWB 227).

RAU ET AL. 2012

Rau, M.; Stollmayer, U.; Kamiske, G. F.: Handbuch QM-Methoden. Die richtige Methode auswählen und erfolgreich umsetzen. 1. Aufl. München: Hanser 2012. ISBN: 978-3-446-42019-9.

REBAI 2010

Rebai, A.: Bayesian Network: IntechOpen 2010. ISBN: 9789533071244.

REICHMANN 1997

Reichmann, T.: Controlling mit Kennzahlen und Managementberichten. Grundlagen einer systemgestützten Controlling-Konzeption. 5. Aufl. München: Vahlen 1997. ISBN: 978-3800621576. (Controlling).

REICHMANN ET AL. 2006

Reichmann, T.; Richter, H. J.; Palloks-Kahlen, M.: Controlling mit Kennzahlen und Management-Tools. Die systemgestützte Controlling-Konzeption. 7. Aufl. München: Verlag Franz Vahlen 2006. ISBN: 978-3-8006-3253-4.

REINARTZ 1999

Reinartz, T.: Focusing Solutions for Data Mining. Analytical Studies and Experimental Results in Real-World Domains. Berlin, Heidelberg: Springer 1999. ISBN: 978-3-540-66429-1. (Lecture Notes in Computer Science 1623).

REINHART ET AL. 2014

Reinhart, G.; Kurfer, J.; Westermeier, M.; Zeilinger, T.: Integrated Product and Process Model for Production System Design and Quality Assurance for EV Battery Cells. Advanced Materials Research 907 (2014), S. 365-378.

RENU ET AL. 2016

Renu, R.; Visotsky, D.; Knackstedt, S.; Mocko, G.; Summers, J. D.; Schulte, J.: A Knowledge Based FMEA to Support Identification and Management of Vehicle Flexible Component Issues. Procedia CIRP 44 (2016), S. 157-162.

RIBEIRO ET AL. 2016

Ribeiro, M. T.; Singh, S.; Guestrin, C.: "Why Should I Trust You?": Explaining the Predictions of Any Classifier. 16.02.2016.

ROMEIKE 2017

Romeike, F.: Risikomanagement: Springer Fachmedien Wiesbaden 2017.

ISBN: 9783658139520.

RUSSELL ET AL. 2016

Russell, S. J.; Norvig, P.; Davis, E.; Edwards, D.: Artificial intelligence. A modern approach. Third edition, Global edition Aufl. Boston: Pearson 2016. ISBN: 9781292153964. (Always learning).

SACHS 1972

Sachs, L.: Statistische Auswertungsmethoden. 3. Aufl. Berlin, Heidelberg, s.l.: Springer Berlin Heidelberg 1972. ISBN: 9783540055204.

SAMMUT & WEBB 2011

Sammuto, C.; Webb, G. I.: Encyclopedia of machine learning. With 78 tables. New York, NY: Springer 2011. ISBN: 9780387307688. (Springer reference).

SAUNDERS 2006

Saunders, C.: Subspace, latent structure and feature selection. Statistical and optimization perspectives workshop, SLSFS 2005 Bohinj, Slovenia, February 23-25, 2005 ; revised selected papers. (Workshop on Subspace, Latent Structure and Feature Selection Techniques: Statistical and Optimization Perspectives). Berlin: Springer 2006. ISBN: 9783540341376. (Lecture Notes in Computer Science 3940).

SCHACHT & LANQUILLON 2019

Schacht, S.; Lanquillon, C.: Blockchain und maschinelles Lernen. Wie das maschinelle Lernen und die Distributed-Ledger-Technologie voneinander profitieren. 1. Aufl: 2019.

ISBN: 978-3-662-60408-3.

SCHÄFER 2003

Schäfer, L.: Analyse und Gestaltung fertigungstechnischer Prozessketten. (Hochschulschrift). Lehrstuhl für Fertigungstechnik und Betriebsorganisation, Universität Kaiserslautern. Kaiserslautern (2003).

SCHENDERA 2007

Schendera, C. F.: Datenqualität mit SPSS. München: Oldenbourg 2007. ISBN: 3486710699.

## SCHMIDT 2013

Schmidt, J. P.: Verfahren zur Charakterisierung und Modellierung von Lithium-Ionen Zellen Band 25 (2013).

## SCHMITT 2020

Schmitt, R. H.: Potenziale Künstlicher Intelligenz für die Qualitätswissenschaft. Berlin, Heidelberg: Springer Berlin Heidelberg 2020. ISBN: 978-3-662-60691-9.

## SCHNEIDER &amp; HEINRICH 2017

Schneider, W.; Heinrich, B.: Praktische Regelungstechnik. Effektiv lernen durch Beispiele. 4. Aufl. Wiesbaden: Springer 2017. ISBN: 3658169931.

## SCHNELL &amp; REINHART 2016

Schnell, J.; Reinhart, G.: Quality Management for Battery Production: A Quality Gate Concept. *Procedia CIRP* 57 (2016), S. 568-573.

## SCHNELL ET AL. 2019

Schnell, J.; Nentwich, C.; Endres, F.; Kollenda, A.; Distel, F.; Knoche, T.; Reinhart, G.: Data mining in lithium-ion battery cell production. *Journal of Power Sources* 413 (2019), S. 360-366.

## SCHOBLOCK 2013

Schoblick, R.: Antriebe von Elektroautos in der Praxis. Motoren, Batterietechnik, Leistungstechnik. 1. Aufl. Haar bei München: Franzis 2013. ISBN: 9783645270311. (Elektronik).

## SCHÖNEMANN 2017

Schönemann, M.: Multiscale Simulation Approach for Battery Production Systems. Cham: Springer International Publishing; Imprint: Springer 2017. ISBN: 9783319493664. (Sustainable Production, Life Cycle Engineering and Management).

## SCHÜPPSTUHL 2018

Schüppstuhl: Tagungsband des 3. Kongresses Montage Handhabung Industrieroboter: Springer Berlin Heidelberg 2018. ISBN: 978-3-662-56713-5.

## SCUTARI &amp; DENIS 2015

Scutari, M.; Denis, J.-B.: Bayesian Networks. With Examples in R. Hoboken: CRC Press 2015. ISBN: 9781482225587. (Chapman & Hall / CRC Texts in Statistical Science).

## SHAEARER 2000

Shaearer, C.: The CRISP-DM Model. The New Blueprint for Data Mining. *Journal of Data Waerhousing*. Vol. 5 Aufl. North Hollywood: Data Waerhousing Institute 2000. (Nummer 4).

SHCHERBAKOV ET AL. 2013

Shcherbakov, M. V.; Brebels, A.; Shcherbakova, N. L.; Tyukov, A. P.; Timur, A.; Janovsky, R.: A Survey of Forecast Error Measures. *Information Technologies in Modern Industry, Education & Society* 24 (2013).

SHEARER 2000

Shearer, C.: The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing* (2000) 5, S. 13-22.

SHWE & COOPER 1991

Shwe, M.; Cooper, G.: An empirical analysis of likelihood-weighting simulation on a large, multiply connected medical belief network. *Computers and Biomedical Research* 24 (1991) 5, S. 453-475.

SIEVERT 2020

Sievert, C.: *Interactive web-based data visualization with R, plotly, and shiny*. Boca Raton, FL: CRC Press, Taylor and Francis Group 2020. ISBN: 9780429824203. (Chapman and Hall/CRC the R series).

SIMON 2013

Simon, R.: Aufbau einer Fabrik zur Zellfertigung. In: Korthauer, R. (Hrsg.): *Handbuch Lithium-Ionen-Batterien*. Berlin, Heidelberg, s.l.: Springer 2013, S. 249-257. ISBN: 978-3-642-30652-5.

SKIRDE ET AL. 2015

Skirde, H.; Kersten, W.; Möller, K.: *Kostenorientierte Bewertung modularer Produktarchitekturen*. (Zugl.: Hamburg-Harburg, Techn. Univ., Institut für Logistik und Unternehmensführung, Diss., 2015) Josef Eul Verlag GmbH; Technische Universität Hamburg-Harburg. 1. Aufl. Lohmar: Eul 2015. ISBN: 9783844104240. (Reihe 20).

SRINIVAS 1993

Srinivas, S.: A Generalization of the Noisy-Or Model. In: Heckerman, D. et al. (Hrsg.): *Uncertainty in Artificial Intelligence*: Elsevier 1993, S. 208-215. ISBN: 9781483214511. (Proceedings of the Ninth international conference on Uncertainty in artificial intelligence).

STATISTA 2020

Statista: Anteile der einzelnen Komponenten am Preis von Elektroautos im Jahr 2020. Online: 2020a.

STATISTA 2020

Statista: Weltweite Preisentwicklung für Lithium-Ionen-Batterien von 2013 bis 2022. Online: 2020b.

## STAUEMEYER 2007

Staudemeyer, J.: Groovy für Java-Entwickler. 1. Aufl. Beijing: O'Reilly 2007.  
ISBN: 9783897214835.

## STAUDER ET AL. 2014

Stauder, R.; Okur, A.; Peter, L.; Schneider, A.; Kranzfelder, M.; Feussner, H.; Navab, N.: Random Forests for Phase Detection in Surgical Workflow Analysis. In: Hutchison, D. et al. (Hrsg.): Information Processing in Computer-Assisted Interventions. Cham: Springer International Publishing 2014, S. 148-157. ISBN: 978-3-319-07520-4. (Lecture Notes in Computer Science).

## STEUER 1999

Steuer, D.: Multi-Criteria-Optimisation and Desirability Indices. 1999.

## STEVEN 2007

Steven, M.: Handbuch Produktion: Theorie - Management - Logistik - Controlling: Kohlhammer 2007. ISBN: 9783170183124.

## TAGUCHI ET AL. 2005

Taguchi, G.; Yano, H.; Chowdhury, S.; Taguchi, S.: Taguchi's quality engineering handbook. Wiley InterScience (Online service). Hoboken, N.J., Livonia, Mich: John Wiley & Sons 2005. ISBN: 0471413348.

## TANIAR 2008

Taniar, D.: Data Mining and Knowledge Discovery Technologies: IGI Pub 2008.  
ISBN: 9781599049618.

## TAPPE 2013

Tappe, S.: Einführung in die Wahrscheinlichkeitstheorie. Berlin, Heidelberg, s.l.: Springer Berlin Heidelberg 2013. ISBN: 978-3-642-37543-9.

## TASCHNER 2017

Taschner, A.: Business Cases. Ein anwendungsorientierter Leitfaden. 3. Aufl. Wiesbaden: Springer Gabler 2017. ISBN: 978-3-658-14678-8.

## TAUSENDPFUND 2019

Tausendpfund, M.: Grafiken mit SPSS. In: Tausendpfund, M. (Hrsg.): Quantitative Datenanalyse. Wiesbaden: Springer Fachmedien Wiesbaden 2019, S. 205-221. ISBN: 978-3-658-27247-0.



TENG & HO 1996

Teng, S.-H.; Ho, S.-Y.: Failure mode and effects analysis. *International Journal of Quality & Reliability Management* 13 (1996) 5, S. 8-26.

THIEDE ET AL. 2019

Thiede, S.; Turetskyy, A.; Kwade, A.; Kara, S.; Herrmann, C.: Data Mining in Battery Production Chains towards multi-criterial Quality Prediction. *Procedia CIRP* (2019).

THIENEN 2013

Thienen, W.: Client/Server. *Moderne Informationstechnologien im Unternehmen*. 2. Aufl. Wiesbaden: Vieweg+Teubner Verlag 2013. ISBN: 9783322868640. (Business Computing).

THOMITZEK ET AL. 2018

Thomitzek, M.; Schmidt, O.; Röder, F.; Krewer, U.; Herrmann, C.; Thiede, S.: Simulating Process-Product Interdependencies in Battery Production Systems. *Procedia CIRP* 72 (2018), S. 346-351.

TURETSKY ET AL. 2018

Turetskyy, A.; Leithoff, R.; Xu, W.; Thiede, S.; Dietrich, F.; Dröder, K.; Herrmann, C.: Assessment of battery cell assembly through non-invasive cell characterization using X-ray computer tomography. *The 31st International Electric Vehicles Symposium and Exhibition & International Electric Vehicle Technology Conference 2018* (2018).

TURETSKY ET AL. 2019

Turetskyy, A.; Thiede, S.; Thomitzek, M.; Drachenfels, N. von; Pape, T.; Herrmann, C.: Toward Data-Driven Applications in Lithium-Ion Battery Cell Manufacturing. *Energy Technology* 12 (2019).

TURETSKY ET AL. 2020

Turetskyy, A.; Wessel, J.; Herrmann, C.; Thiede, S.: Data-driven cyber-physical System for Quality Gates in Lithium-ion Battery Cell Manufacturing. *Procedia CIRP* 93 (2020), S. 168-173.

ULLMANN 2010

Ullmann, G.: *Expertensystem zur Bereitstellung von Produktionssystem-Wissen für den Werkzeug- und Formenbau*. (Zugl.: Hannover, Univ., Diss., 2010). Garbsen: PZH Produktionstechn. Zentrum 2010. ISBN: 9783941416826. (Berichte aus dem IPH 2010,5).

ULRICH & PROBST 1995

Ulrich, H.; Probst, G. J.: *Anleitung zum ganzheitlichen Denken und Handeln. Ein Brevier für Führungskräfte*. 4., unveränd. Aufl. Aufl. Bern: Haupt 1995. ISBN: 3258051828.

ULRICH 2016

Ulrich, S.: Umgang mit Störungen im Produktionsanlauf. (Dissertation)Josef Eul Verlag GmbH (2016).

VDA Band 4

VDA Band 4: Qualitätsmanagement in der Automobilindustrie: VDA 2012.

VDMA 2018

VDMA (Hrsg.): Roadmap Batterie-Produktionsmittel 2030. Update 2018. Frankfurt am Main: VDMA Verlag GmbH 2018.

VMDA 2018

VMDA: Roadmap Batterie-Produktionsmittel 2030. VDMA (2018).

VMDA 66412-1

VMDA 66412-1: 66412-1: Beuth 2019-10.

WEISER 2018

Weiser, A.-K.: Methodik eines holistischen Variantenmanagements modularer Produktfamilien. (Dissertation)Karlsruher INstitut für Technologie (KIT). Karlsruhe (2018). <<http://nbn-resolving.de/urn:nbn:de:0072-810700>>.

WENGLER 1996

Wengler, M. M.: Methodik für die Qualitätsplanung und -verbesserung in der Keramikindustrie. Ein Beitrag zum Qualitätsmanagement bei der Planung neuer und der Optimierung bestehender Prozesse. (Zugl.: Aachen, Techn. Hochsch., Diss., 1996). Als Ms. gedr Aufl. Düsseldorf: VDI-Verl. 1996. ISBN: 3-18339-202-X. (Fortschritt-Berichte VDI Reihe 2, Fertigungstechnik 392).

WERDICH 2012

Werdich, Martin (Hrsg.): FMEA - Einführung und Moderation. Durch systematische Entwicklung zur übersichtlichen Risikominimierung (inkl. Methoden im Umfeld). 2. Aufl. Wiesbaden: Springer Vieweg 2012. ISBN: 978-3-8348-1787-7.

WESTERMEIER 2016

Westermeier, M.: Qualitätsorientierte Analyse komplexer Prozessketten am Beispiel der Herstellung von Batteriezellen. München: Utz, Herbert 2016. ISBN: 978-3-8316-4586-2. (Forschungsberichte IWB 322).

WESTERMEIER ET AL. 2013

Westermeier, M.; Reinhart, G.; Zeilinger, T.: Method for quality parameter identification and

classification in battery cell production quality planning of complex production chains for battery cells (2013), S. 1-10.

WESTERMEIER ET AL. 2014

Westermeier, M.; Reinhart, G.; Steber, M.: Complexity Management for the Start-up in Lithium-ion Cell Production. *Procedia CIRP* 20 (2014), S. 13-19.

WICKHAM 2016

Wickham, H.: *ggplot2. Elegant graphics for data analysis*. Cham: Springer 2016. ISBN: 978-3-319-24275-0. (Use R!).

WILHELM 2006

Wilhelm, S.: Verfahren zur Einführung eines internetbasierten Content-Management für Qualitätsregelkreise in der Produktion. (Zugl.: Stuttgart, Univ., Diss, 2005) Universität Stuttgart. Heimsheim: Jost-Jetter 2006. ISBN: 3-936947-81-3. (IPA-IAO-Forschung und -Praxis Nr. 434).

WIRAEUS ET AL. 2019

Wiraeus, D.; Creelman, J.; Norton, D. P.: *Agile strategy management in the digital age. How dynamic balanced scorecards transform decision making, speed and effectiveness*. Cham, Switzerland: Palgrave Macmillan 2019. ISBN: 978-3-319-76308-8.

WOHLRABE 2009

Wohlrabe, H.: *Qualitätsoptimierung bei der Fertigung elektronischer Baugruppen mittels statistischer Analysemethoden*. (Zugl.: Dresden, Techn. Univ., Habil.-Schr., 2008). 1. Aufl. Templin: Detert 2009. ISBN: 9783934142329. (System integration in electronic packaging 7).

WÖHRLE 2013

Wöhrle, T.: Lithium-Ionen-Zelle. In: Korthauer, R. (Hrsg.): *Handbuch Lithium-Ionen-Batterien*. Berlin, Heidelberg, s.l.: Springer 2013, S. 107-117. ISBN: 978-3-642-30652-5.

WOLF & BEST 2010

Wolf, C.; Best, H.: *Handbuch der sozialwissenschaftlichen Datenanalyse*. 1. Aufl. Wiesbaden: VS Verlag für Sozialwissenschaften / Springer Fachmedien Wiesbaden GmbH Wiesbaden 2010. ISBN: 3531920383.

WURM ET AL. 2013

Wurm, C.; Öttinger, O.; Wittkämper, S.; Zauter, R.; Vuorilehto, K.: Anodenmaterialien für Lithium-Ionen-Batterien. In: Korthauer, R. (Hrsg.): *Handbuch Lithium-Ionen-Batterien*. Berlin, Heidelberg, s.l.: Springer 2013, S. 45-60. ISBN: 978-3-642-30652-5.

YAO ET AL. 2018

Yao, Q.; Wang, M.; Chen, Y.; Dai, W.; Li, Y.-F.; Tu, W.-W.; Yang, Q.; Yu, Y.: Taking Human out of Learning Applications: A Survey on Automated Machine Learning. 31.10.2018.

YOSHIO 2009

Yoshio, M.: Lithium-Ion Batteries. Science and Technologies. New York, NY: Springer-Verlag New York 2009. ISBN: 978-0-38734-444-7.

ZADEH 1965

Zadeh, L. A.: Fuzzy sets. Information and Control (1965) 3, S. 338-353.

ZAGORECKI & DRUZDZEL 2013

Zagorecki, A.; Druzdzal, M. J.: Knowledge Engineering for Bayesian Networks: How Common Are Noisy-MAX Distributions in Practice? IEEE Transactions on Systems, Man, and Cybernetics: Systems 43 (2013) 1, S. 186-195.

ZIELOWSKI 2006

Zielowski, C.: Managementkonzepte aus Sicht der Organisationskultur. 1. Aufl. s.l.: DUV Deutscher Universitäts-Verlag 2006. ISBN: 9783835002227. (Techno-ökonomische Forschung und Praxis).

ZSW 2020

ZSW: Zahl der Elektroautos steigt weltweit von 5,6 auf 7,9 Millionen. <[https://www.zsw-bw.de/fileadmin/user\\_upload/pi03-2020-ZSW-WeltweiteZahlenElektroautos.pdf](https://www.zsw-bw.de/fileadmin/user_upload/pi03-2020-ZSW-WeltweiteZahlenElektroautos.pdf)> - 07.04.2020.

## 8 Anhang

### 8.1 Kennzahlen

Tabelle 8-1: Übersicht etablierter Qualitätskennzahlen nach LINQ 2013, S. 457-458 und VMDA 2018.

Kennzahl	Berechnungsformel	Kurzbeschreibung
Qualitätsrate	$\frac{GM}{PM}$	Verhältnis der Gutmenge zur produzierten Menge
Ausschussquote	$\frac{AM}{PM}$	Verhältnis des Ausschusses zur produzierten Menge
Fehlerquote	$\frac{\text{Anzahl Defekte}}{\text{Anzahl abgeschlossener Vorgänge}} \cdot \frac{1}{\text{Fehlermöglichkeiten pro Vorgang}}$	Verhältnis der aufgetretenen Defekte zu den Fehlermöglichkeiten aller Vorgänge
Nacharbeitsquote	$\frac{NM}{PM}$	Prozentuale Quote der Nacharbeit bezogen auf die produzierte Menge
Fall of Rate	$\frac{PM_{\text{im ersten AG}} - PM_{\text{vom aktuellen AG}}}{PM_{\text{im ersten AG}}}$	Ausfallanteil in Bezug auf die im ersten Arbeitsgang produzierte Menge (für verkettete Prozesse)
DPMO	Fehlerquote · 1.000.000	Defects per Million Opportunities (deutsch: Fehler pro Million Möglichkeiten)
First Pass Yield	$\frac{GT}{PT}$	Prozentsatz der i.O.-Produkte aus dem ersten Prüfdurchlauf. Reziproker Wert der Fehlleistungskosten
Sigma-Level	$\frac{OGW - UGW}{2 \sigma}$	Vergleichskenngröße der Prozessgüte

Tabelle 8-2: Übersicht der Prozessbewertungsgrößen DPMO, Prozessfähigkeiten, Yield und Six Sigma Level (LINß 2013, S. 626).

$\sigma$ -Level	Prozess mit $\mu$ = Sollwert				Prozess mit $\mu$ = Sollwert $\pm$ 1,5 $\sigma$			Einstufung
	$C_p$	$C_{pk}$	Yield [%]	DPMO	$C_{pk}$	Yield [%]	DPMO	
1	0,33	0,33	68,26895	317.311	0,00	30,23279	697.672	Nicht wettbe- werbsfähig
2	0,67	0,67	95,44999	45.500	0,17	69,12298	308.770	
3	1,00	1,00	99,73001	2.700	0,50	93,31894	66.811	Durchschnittsun- ternehmen
4	1,33	1,33	99,99366	63	0,83	99,37903	6.210	
5	1,67	1,67	99,99994	0,6	1,17	99,97673	233	
6	2,00	2,00	100,0000	0,00197	1,50	99,99966	3,4	Weltklasse
7	2,33	2,33	100,0000	0,0000	1,83	99,999998	0,019	




Abbildung 79: Übersetzung der Punktergabe von Auftretenswahrscheinlichkeit in A-priori-Wahrscheinlichkeit (KMENTA & ISHII 2004, S. 1031).

## 8.2 Beispielrechnung einer Fehler-Ursachen-Analyse

Die Ursachenwahrscheinlichkeiten des Fehlernetzwerkes aus Abbildung 42 lassen sich mit Hilfe des Bayes-Theorems berechnen (vgl. Kapitel 2.2.10). Die Ursachenwahrscheinlichkeit

von Fehler  $F_2$  unter der Bedingung (Evidenz), dass  $F_1$  aufgetreten ist und  $F_3$  als Fehler ausgeschlossen werden kann, lässt sich bestimmen durch:

$$P(f_2|f_1, \neg f_3) = \frac{P(f_1, \neg f_3|f_2)P(f_2)}{P(f_1, f_2, \neg f_3) + P(f_1, \neg f_2, \neg f_3)} \quad (8.1)$$

Mithilfe des Satzes der bedingten Wahrscheinlichkeit (vgl. TAPPE 2013, S. 19) kann eine Umformung des Zählers erfolgen zu:

$$P(f_1, \neg f_3|f_2)P(f_2) = P(f_1, f_2, \neg f_3) \quad (8.2)$$

Für die Berechnung der Ursachenwahrscheinlichkeit des Fehlers  $F_2$  gilt somit:

$$P(f_2|f_1, \neg f_3) = \frac{P(f_1, f_2, \neg f_3)}{P(f_1, f_2, \neg f_3) + P(f_1, \neg f_2, \neg f_3)} \quad (8.3)$$

Eine Berechnung der einzelnen Summanden erfolgt kombinatorisch über die Fehlerknoten  $F_4, F_5$  und  $F_6$  mithilfe des Satzes der Totalen Wahrscheinlichkeit (vgl. Formel (8.4) und (8.5)). Eine Betrachtung der Fehlerkombination von  $F_3$  und  $F_1$  findet dabei nicht statt, da die Zustände der Fehlerknoten bereits bekannt sind.

$$\begin{aligned} P(f_1, f_2, \neg f_3) &= \sum_{F_4, F_5, F_6} P(f_1, f_2, \neg f_3, F_4, F_5, F_6) = \\ \sum_{F_4, F_5, F_6} P(f_1|f_2, \neg f_3, F_5) \cdot P(f_2|F_4, F_6) \cdot P(\neg f_3) \cdot P(F_4) \cdot P(F_5) \cdot P(F_6) &= 0,00172 \end{aligned} \quad (8.4)$$

$$\begin{aligned} P(f_1, \neg f_2, \neg f_3) &= \sum_{F_4, F_5, F_6} P(f_1, \neg f_2, \neg f_3, F_4, F_5, F_6) = \\ \sum_{F_4, F_5, F_6} P(f_1|\neg f_2, \neg f_3, F_5) \cdot P(\neg f_2|F_4, F_6) \cdot P(\neg f_3) \cdot P(F_4) \cdot P(F_5) \cdot P(F_6) &= 0,00951 \end{aligned} \quad (8.5)$$





Ausgehend von den Ergebnissen von Tabelle 8-3 und Tabelle 8-4 lässt sich die Ursachenwahrscheinlichkeit von Fehler  $F_2$  bestimmen:

$$P(f_2|f_1, \neg f_3) = \frac{P(f_1, f_2, \neg f_3)}{P(f_1, f_2, \neg f_3) + P(f_1, \neg f_2, \neg f_3)} = \frac{0,00172}{0,00172 + 0,00951} = 0,153 \triangleq 15,3\% \quad (8.6)$$

Die Fehlerursachenwahrscheinlichkeiten für  $F_5$ ,  $F_4$  und  $F_6$  lassen sich analog zum vorgestellten Ansatz berechnen als  $F_5 = 0,8637$ ,  $F_4 = 0,1201$  und  $F_6 = 0,0385$ .

### 8.3 Deskriptive Statistik

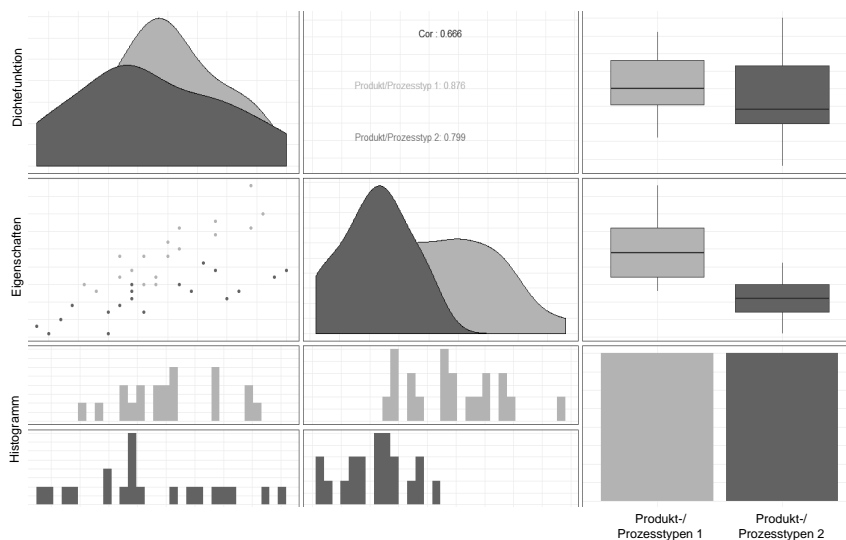


Abbildung 80: Beispiel multivariater Visualisierungen der deskriptiven Statistik (in Anlehnung an TAUSENDPFUND 2019, S. 205-221).




Abbildung 81: Beispiel eines Histogramms zur Bestimmung von Ausreißern (UAG = untere Ausreißergrenze, OAG= obere Ausreißergrenze, USG= untere Spezifikationsgrenze, OSG= obere Spezifikationsgrenze).



**Institut für Werkzeugmaschinen  
und Fertigungstechnik**  
der Technischen Universität  
Carolo-Wilhelmina zu Braunschweig

Prof. Dr.-Ing. Klaus Dröder  
Prof. Dr.-Ing. Christoph Herrmann

Langer Kamp 19 B  
D - 38106 Braunschweig  
Telefon +49(0)531 / 391-7601  
Telefax +49(0)531 / 391-5842  
E-Mail [iwf-braunschweig@tu-braunschweig.de](mailto:iwf-braunschweig@tu-braunschweig.de)  
Internet <http://www.tu-braunschweig.de/iwf>

**ISBN 978-3-8027-8363-0**